

Metodología para la elaboración de pronósticos en la unidad de negocio de agroquímicos de una multinacional química integrando juicio humano con computador

Trabajo de grado presentado como requisito parcial para obtener el título de

Magister en Gerencia de Operaciones
(Modalidad de Profundización)

Shirley Tatiana Usuga Espinal

Director:
Jorge Andrés Alvarado
M.S Analytics, Master en Educación

Presentado públicamente el día 7 de Febrero de 2014

Jurado:
Jairo R. Montoya Torres, Universidad de la Sabana
Amelec Jesús Viloria Silva, Universidad Javeriana

Universidad de La Sabana
Escuela Internacional de Ciencias Económicas y Administrativas
Chía, Colombia
2014

TABLA DE CONTENIDO

1.	FORMULACIÓN DEL PROBLEMA DE INVESTIGACIÓN Y ANTECEDENTES	1
1.1.	MOTIVACIÓN	1
1.2.	ANTECEDENTES DEL CASO DE ESTUDIO	2
1.2.1.	METODOLOGÍA ACTUAL EN LA EMPRESA PARA PLANIFICACIÓN DE DEMANDA	3
1.2.2.	CÁLCULO INDICADORES DE PRONÓSTICO.....	4
1.2.3.	CÁLCULO INDICADORES DE INVENTARIO	4
1.3.	ANTECEDENTES TEORICOS Y FORMULACION DEL PROBLEMA.....	5
2.	OBJETIVOS DE INVESTIGACIÓN	8
2.1.	OBJETIVO GENERAL	8
2.2.	OBJETIVOS ESPECÍFICOS	8
3.	JUSTIFICACIÓN Y DELIMITACIÓN DEL ESTUDIO	8
4.	MARCO TEÓRICO	9
4.1.	PRONOSTICAR	9
4.2.	MÉTODOS DE PRONÓSTICO	9
4.3.	DISEÑO EXPERIMENTAL.....	11
4.4.	CUADRADO LATINO	12
5.	METODOLOGÍA DE LA INVESTIGACIÓN Y DESARROLLO	13
5.1.	GENERACIÓN DE UN MODELO GENÉRICO DE PRONÓSTICOS	13
5.1.1.	TOMA DE DATOS	13
5.1.2.	TRATAMIENTO DE LOS DATOS	15
5.1.3.	MODELOS DE REGRESIÓN LINEAL	23
5.2.	APLICACIÓN DE MÉTRICAS A CADA MODELO	23
5.2.1.	FINAL FORECAST ACCURACY & BIAS %	23
5.2.2.	DÍAS DE INVENTARIO.....	24
5.3.	MODELO ENTRENAMIENTO Y VALIDACIÓN.....	25
5.4.	DISEÑO EXPERIMENTAL APLICADO	27
5.4.1.	VARIABLES DE RESPUESTA.....	27
5.4.2.	FUENTES DE VARIACIÓN.....	27
5.4.3.	MODELO MATEMÁTICO.....	30
5.4.4.	PROTOCOLO.....	30
5.4.5.	RESULTADOS DEL EXPERIMENTO	32
6.	EVALUACIÓN ECONÓMICA	34
7.	METODOLOGÍA DE IMPLEMENTACIÓN	36

8. CONCLUSIONES	39
BIBLIOGRAFIA CONSULTADA.....	40
ANEXO 1. INCLUSIÓN DE PRECIPITACIONES PARA CADA UNO DE LOS MODELOS....	42
ANEXO 2. ANALISIS ANOVA PARA LAS REGRESIONES LINEALES	44
ANEXO 3. VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – SIN CLASIFICACION	46
ANEXO 3. VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – GRUPO A	48
ANEXO 3. VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – GRUPO B	50
ANEXO 3. VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – INSECTICIDAS	52
ANEXO 3. VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – HERBICIDAS	54
ANEXO 3. VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – FUNGICIDAS	56
ANEXO 3. VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – COAYUDANTES	58
ANEXO 3. VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – FERTILIZANTES.....	60
ANEXO 4. ANALISIS DE CORRELACION ENTRE VARIABLES.....	62
ANEXO 5. ANALISIS ANOVA DEL DISEÑO EXPERIMENTAL	64

LISTA DE TABLAS

TABLA 1. EJEMPLO DE CÁLCULO DE <i>FORECAST ACCURACY</i>	4
TABLA 2. PROMEDIOS DE PRECIPITACIONES (MM) POR LA REGIÓN ANDINA – ÚLTIMOS 30 AÑOS FUENTE: IDEAM, GRUPO DE MODELAMIENTO DE TIEMPO Y CLIMA. SUBDIRECCIÓN DE METEOROLOGÍA.	14
TABLA 3. PRONÓSTICOS DE PRECIPITACIONES PARA LA ZONA ANDINA (ENERO A SEPTIEMBRE 2013).....	15
TABLA 4. RESUMEN DEL MODELO - SIN CLASIFICACIÓN.....	16
TABLA 5. COEFICIENTES - SIN CLASIFICACIÓN.....	17
TABLA 6. RESUMEN DE MÉTRICAS PARA REGRESIONES INDIVIDUALES	17
TABLA 7. RESUMEN DEL MODELO – CLASIFICACIÓN PROPUESTA GRUPO A.....	18
TABLA 8. COEFICIENTES - CLASIFICACIÓN PROPUESTA GRUPO A	18
TABLA 9. RESUMEN DEL MODELO – CLASIFICACIÓN PROPUESTA GRUPO B.....	19
TABLA 10. COEFICIENTES - CLASIFICACIÓN PROPUESTA GRUPO B.....	19
TABLA 11. RESUMEN DEL MODELO – CLASIFICACIÓN ANDI – INSECTICIDAS.....	19
TABLA 12. COEFICIENTES - CLASIFICACIÓN ANDI – INSECTICIDAS	20
TABLA 13. RESUMEN DEL MODELO – CLASIFICACIÓN ANDI – HERBICIDAS	20
TABLA 14. COEFICIENTES - CLASIFICACIÓN ANDI – HERBICIDAS.....	20
TABLA 15. RESUMEN DEL MODELO – CLASIFICACIÓN ANDI – FUNGICIDAS	21
TABLA 16. COEFICIENTES - CLASIFICACIÓN ANDI – FUNGICIDAS.....	21
TABLA 17. RESUMEN DEL MODELO – CLASIFICACIÓN ANDI – COAYUDANTES	22
TABLA 18. COEFICIENTES - CLASIFICACIÓN ANDI – COAYUDANTES	22
TABLA 19. INCLUSIÓN DE PRECIPITACIONES – CLASIFICACIÓN ANDI – FERTILIZANTES.....	22
TABLA 20. COEFICIENTES - CLASIFICACIÓN ANDI – FERTILIZANTES.....	23
TABLA 21. RESUMEN MODELOS DE REGRESIÓN.	23
TABLA 22. RESUMEN VALIDACIÓN DE MODELOS MESES OCTUBRE - NOVIEMBRE.....	26
TABLA 23. –INTERVALOS DE CONFIANZA PARA CADA MÉTODO - VARIABLE DEPENDIENTE: MEJORAMIENTO DE MAPE FRENTE A PRONÓSTICO INGENUO	33
TABLA 24. –INTERVALOS DE CONFIANZA PARA CADA MÉTODO - VARIABLE DEPENDIENTE: MEJORAMIENTO DE MAPE FRENTE A PRONÓSTICO DEL SISTEMA.....	34
TABLA 25. COMPARATIVO EN INDICADORES PERIODO ENERO - NOVIEMBRE.....	34

LISTA DE FIGURAS

FIGURA 1. FORECAST ACCURACY – BIAS% 2012 – NOVIEMBRE 2013.....	3
FIGURA 2. DIAGRAMA DE PLANEACIÓN DE DEMANDA Y ANÁLISIS DE SUMINISTRO.....	3
FIGURA 3. DIV YTD Y PIT - DICIEMBRE 2013.....	5
FIGURA 4. REGIÓN ANDINA.....	14
FIGURA 5. CLASIFICACIÓN PROPUESTA SOBRE LOS 23 PRODUCTOS DE ESTUDIO.....	18
FIGURA 6. MODELO SIN CLASIFICACIÓN: COMPARACIÓN DE MÉTRICAS SITUACIÓN ACTUAL VS. PROPUESTA (<i>FINAL FORECAST ACCURACY – BIAS %</i>)	24
FIGURA 7. MODELO CLASIFICACIÓN PROPUESTA: COMPARACIÓN DE MÉTRICAS SITUACIÓN ACTUAL VS. PROPUESTA (<i>FINAL FORECAST ACCURACY – BIAS %</i>)	24
FIGURA 8. MODELO CLASIFICACIÓN ANDI: COMPARACIÓN DE MÉTRICAS SITUACIÓN ACTUAL VS. PROPUESTA (<i>FINAL FORECAST ACCURACY – BIAS %</i>)	24
FIGURA 9. MODELO SIN CLASIFICACIÓN: COMPARACIÓN DE MÉTRICAS SITUACIÓN ACTUAL VS. PROPUESTA (DÍAS DE INVENTARIO DIV YTD.....)	25
FIGURA 10. MODELO CLASIFICACIÓN PROPUESTA: COMPARACIÓN DE MÉTRICAS SITUACIÓN ACTUAL VS. PROPUESTA (DÍAS DE INVENTARIO DIV YTD.....)	25
FIGURA 11. MODELO CLASIFICACIÓN ANDI: COMPARACIÓN DE MÉTRICAS SITUACIÓN ACTUAL VS. PROPUESTA (DÍAS DE INVENTARIO DIV YTD.....)	25
FIGURA 12. MEDIAS MARGINALES ESTIMADAS DE MAPETOTAL.....	32
FIGURA 13. MEDIAS MARGINALES ESTIMADAS DE MAPEIMPROVEMENTNAIVE	33
FIGURA 14. COMPARATIVO EN INDICADORES PERIODO ENERO – NOVIEMBRE	34
FIGURA 15. COMPARATIVO DIV (YTD) PERIODO ENERO – NOVIEMBRE.....	35
FIGURA 16. VALOR DEL INVENTARIO CON MODELO ACTUAL Y SUGERIDO. PERIODO ENERO – NOVIEMBRE	35
FIGURA 17. METODOLOGÍA DE IMPLEMENTACIÓN PARA LA ELABORACIÓN DE PRONÓSTICOS.....	38

1. FORMULACIÓN DEL PROBLEMA DE INVESTIGACIÓN Y ANTECEDENTES

Esta investigación se enmarca como caso de estudio dentro de la Tesis Doctoral de Jorge Andrés Alvarado, la cual busca comparar, en diferentes compañías, tres métodos de integración de juicio humano y pronósticos estadísticos.

1.1. MOTIVACIÓN

Los mercados cada vez son más competitivos y las compañías están inmersas en una lucha constante por su participación de mercado y crecimiento. Ante este desafío, una planeación de demanda certera juega un rol importante.

La planeación de demanda es el proceso de analizar, evaluar, proyectar y comunicar los futuros requerimientos de los clientes (Techopedia, 2013). El propósito de planificar la demanda no es otro que: generar la estimación de ventas para la organización, es decir, qué fracción de la demanda será posible satisfacer con la producción de sus bienes y/o servicios. Por esta razón, contar con un sistema efectivo de planificación de la demanda, permitirá a la organización proyectar eficientemente sus actividades y procesos, cumpliendo con sus presupuestos de ingresos y de sus costos, sin perder de vista sus políticas y presupuestos, alcanzando -de esta forma- sus objetivos estratégicos. (Logistec, 2013). Juega un rol importante en el flujo de efectivo de cualquier empresa y de diferentes formas, por ejemplo en generación de ventas - más asertividad en la demanda contribuye a altos niveles de servicio a los clientes -, en reducción de costos operativos -en la medida que la producción es efectiva y mejor proyectada-, y mejoramiento del capital de trabajo.

Una de las herramientas de la planeación de demanda son los pronósticos, estos sirven para anticiparse o predecir eventos futuros. Según revisión de varias encuestas de Sanders y Manrodt (2003) en los pronósticos usualmente se incluyen juicio humano y pronósticos estadísticos, es decir, algunas compañías hacen uso de herramientas estadísticas y otras de forma poco ortodoxa hacen uso del juicio de sus expertos al tanteo para producir los pronósticos.

La mayoría de empresas toman como pronósticos aquellos que los comerciales presentan basados en su intuición; sin embargo, estos pronósticos tienden a ser metas y no verdaderas estimaciones de las posibles ventas. (Sanders & Manrodt, 1994), (Sanders, 1997), (Sanders & Manrodt, 2003).

Estos pronósticos intuitivos son importantes, pero las investigaciones han demostrado que fácilmente pueden verse afectados por sesgos que eliminan las supuestas ventajas que puedan tener, haciendo que sus resultados sean pobres. (Lawrence, Goodwin, O'Connor, & Onkal, 2006)

Para que las empresas puedan reducir el grado de incertidumbre como resultado del cambio constante del entorno, deben respaldar sus decisiones en algo más que la intuición; deben respaldarlo en la elaboración de pronósticos correctos y precisos que sean suficientes para satisfacer las necesidades de planeación de la organización, (Hanke & Wichem, 2006). De ahí que se considere que los pronósticos más completos suelen estar acompañados de juicio de expertos, intuición, 'feeling', sabor del mercado y cifras duras. De aquí que esta investigación busca analizar una alternativa para integrar el juicio del experto con la cifra estadística.

1.2. ANTECEDENTES DEL CASO DE ESTUDIO

El desarrollo de esta investigación se hizo para una multinacional química, la cual produce y vende productos para las industrias de petróleo, gas, plástico, construcción, cuidado personal, farmacéutica, pinturas y agroquímicos. Ha desarrollado más de 8.000 productos y patentes, que están presentes en la vida diaria como la alimentación, vivienda, vestido, salud, comunicación y transporte. Las constantes investigaciones y descubrimientos les han permitido ir siempre a la vanguardia en el mundo de la química y petroquímica. Consta con alrededor de 200 fábricas que proveen una excelente infraestructura y alto valor para los productos desarrollados. Cuenta con una red de producción y distribución de 345 filiales a nivel mundial y tiene relaciones comerciales con 170 países. Contando en todo el mundo, son 111.000 empleados en los 5 continentes.

La investigación solo se enfoca en el negocio de agroquímicos, el más importante después del petroquímico. Con este negocio ha logrado desarrollar productos que protegen de manera eficaz y ecológica la producción tecnificada de alimentos y flores. Cuenta con 7 líneas de productos entre los que destacan: Coayudantes, Herbicidas, Fungicidas, Insecticidas y Fertilizantes, mediante los cuales atiende el mercado agrícola colombiano, con énfasis en cultivos de alto valor y gran superficie. Se tomará un grupo de productos los cuales tienen la más alta participación en ventas y demanda restringida.

En los años 2012 y 2013 se vivió una crisis en el mercado de agroquímicos debido a las altas temperaturas (escases de lluvias), las cuales frenaron las ventas de la mayoría de líneas. Para cuando se comenzó esta investigación en Abril de 2013, el desempeño de la multinacional había estado por debajo del mercado en un 9% y el mercado presentaba un desempeño del 4% superior al mostrado en el año 2012.

Es importante que la empresa química hubiera entrado como caso de estudio, debido a que aparte de su bajo desempeño de mercado, se había evidenciado notablemente un desbalanceo de inventarios, bajo nivel de servicio con algunos productos y aumento de ventas perdidas.

Los tres principales indicadores del proceso de planeación de demanda en la multinacional son el *final forecast accuracy*, los días de inventario y el *bias%*. Revisando los KPI's al comienzo de esta investigación se tenía una exactitud de pronósticos (*Forecast Accuracy*) no superior al 55% en el año 2012 en el negocio agroquímico y el *bias%* era de -23% (ver Figura 1) y en el mes de noviembre al finalizar la investigación estaba en 19% y en un 50% respectivamente; sus días de inventario (YTD) en abril de 2013 estaban en 170 días (ver Figura 3) en diciembre había cerrado en 164 días. Las metas esperadas al cerrar el año 2013 eran de 106 días de inventario (YTD), *Final Forecast Accuracy* superior al 70% y *Bias%* debía ser por debajo del 28% y superior o igual 0%.

Como se puede observar, las metas estaban lejos de ser alcanzadas con el proceso actual de pronósticos.




Figura 1. Forecast Accuracy – Bias% 2012 – Noviembre 2013

Fuente: Multinacional Química

1.2.1. METODOLOGÍA ACTUAL EN LA EMPRESA PARA PLANIFICACIÓN DE DEMANDA

La metodología para planificación de demanda en la multinacional química, se hace de la siguiente forma:

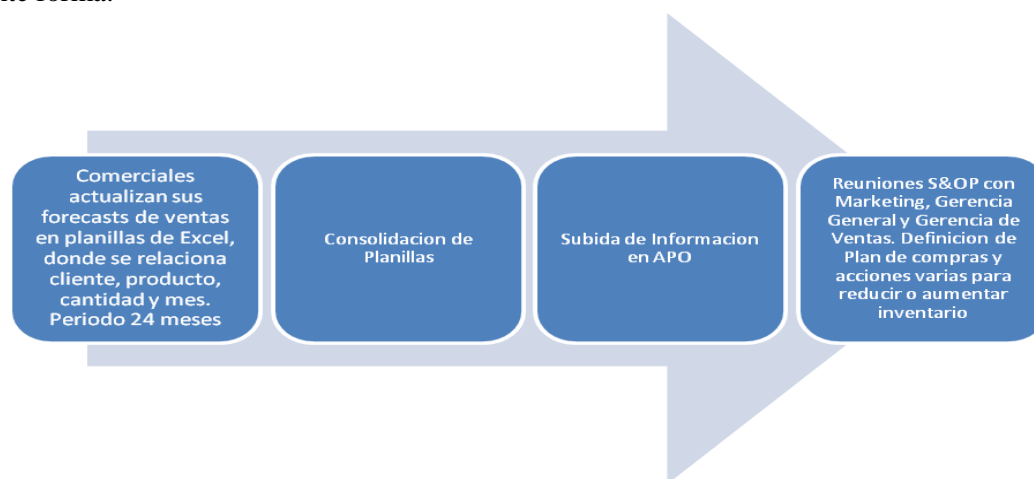


Figura 2. Diagrama de Planeación de Demanda y Análisis de Suministro

Fuente: Multinacional Química

Todos los pronósticos comerciales son subidos al planificador y optimizador avanzado o APO (sigla en inglés de *Advanced Planning and Optimizer*), de tal forma que las filiales puedan visualizar la demanda en los próximos 24 meses y en ese orden planificar su producciones.

Se observa entonces que, en la multinacional química, la planificación de la demanda solo se reduce al hecho de recolectar la información del comercial sobre pronósticos de venta y cotejar con marketing y gerencia de ventas las variabilidades. No se hace uso de herramientas estadísticas para producir pronósticos y compararlos con los dados por los comerciales, pese a que se dispone de la herramienta APO.

1.2.2. CÁLCULO INDICADORES DE PRONÓSTICO

El proceso de cálculo de cada indicador se especifica a continuación:

Forecast accuracy

La exactitud de pronósticos (*forecast accuracy*), se define dentro de la compañía como el indicador que mide la asertividad entre el pronóstico de ventas y las ventas reales.

1. Para el negocio de agroquímicos se mide acumulado a tres meses: Se hace la sumatoria para cada artículo de los pronósticos de ventas de los últimos tres meses.
2. Se hace la sumatoria para cada artículo de las ventas de los últimos tres meses.
3. Se calcula para cada artículo la diferencia absoluta entre los pronósticos de ventas y la venta.
4. Se sacan los totales para el trimestre evaluado tanto de los pronósticos de ventas, de las ventas y de las diferencias absolutas.
5. Se calcula el MAPE (*mean absolute percent error*), el cual es el total del valor absoluto de la diferencia entre ventas y pronósticos dividido el total de las ventas.
6. Finalmente el *Forecast Accuracy* está determinado por la diferencia de 1 menos el MAPE.

Porcentaje Bias

- El %Bias que se observa en la figura 1, está determinado por la diferencia entre los pronósticos de ventas y la venta total del trimestre dividido la venta total del mismo periodo.

Final Forecast Accuracy

- *FINAL FORECAST ACCURACY* es el resultado final y refleja el porcentaje obtenido en el *forecast accuracy*, si este porcentaje no estuvo entre 1% y el 100%, entonces el *FINAL FORECAST ACCURACY* será cero.

Tabla 1. Ejemplo de Cálculo de *Forecast Accuracy*

Forecast Accuracy Calculation	Forecast ENERO	Sales ENERO	MAPE	Forec. Accuracy	Final Forec. Accuracy
ene-13	121.086	60.615	169%	-69%	0%

En este caso, la desviación fue del 169 %. El pronóstico fue del -69%. La suma del MAPE y del pronóstico siempre debe ser 100%. Como el *Forecast Accuracy* no se encuentra dentro del rango de 1% a 100% su resultado final es cero.

1.2.3. CÁLCULO INDICADORES DE INVENTARIO

Días de Inventario

Los días de inventario se calculan con el indicador DIV YTD (*Days Of Inventory Value Year Today*), el cual se determina de la siguiente ecuación (1):

$$\text{DIV YTD} = \frac{\text{Valor del inventario promedio desde comienzos del año}}{\text{Valor de la venta promedio desde comienzos del año}} \quad (1)$$

Se traduce como los días de inventario acumulados del año en curso.

Y el DIV PIT (*Days of Inventory Point in time*), se determina como sigue en la ecuación (2):

$$\text{DIV PIT} = \frac{\text{Valor del inventario al final del mes}}{\text{Valor de la venta promedio en los ultimos 90 dias}} \quad (2)$$




Figura 3. DIV YTD y PIT - Diciembre 2013

Fuente: Multinacional Química

1.3. ANTECEDENTES TEORICOS Y FORMULACION DEL PROBLEMA

El objetivo de un pronóstico es doble: lograr la mayor precisión posible y hacer la mayor disminución posible del riesgo y su mejor valoración para mejorar la planeación (Alvarado, 2014). En la medida en que logre simultáneamente estos dos objetivos se puede afirmar que un pronóstico es de calidad. Este concepto de calidad está alineado con la propuesta de robustez en el diseño de Genichi Taguchi. En particular, Taguchi propone que un proceso es robusto cuando es poco sensible a los efectos de fuentes de variabilidad externas al mismo (ruido ambiental) (Alvarado, 2014). Un proceso de calidad, según Taguchi, es aquel cuyas características se ajustan a un desempeño específico requerido por el cliente y son robustos, es decir, mantienen su desempeño sin mayor variabilidad en un rango amplio de contextos, (Fowlkes & Creveling, 1995). En el caso de los pronósticos, el desempeño requerido es lograr la mayor precisión posible por encima de un pronóstico ingenuo y que dicha precisión varíe lo menos posible en diferentes contextos, es decir, sea robusta. De ese modo la valoración del riesgo es más fácil.

En el párrafo anterior se menciona el pronóstico ingenuo, el cual supone que el siguiente periodo de ventas será el mismo que el correspondiente al periodo anterior. Obviamente en muy pocos casos los pronósticos ingenuos son adecuados debido a la volatilidad del mercado (Alvarado, 2014). Sin embargo en ocasiones los pronósticos de juicio empeoran aún más el pronóstico frente a la línea de base ingenua, y por ello es indispensable compararse con ella. Esto para garantizar que se agregue valor en el proceso.

El mejoramiento de la calidad de los pronósticos depende de cuatro factores: información disponible, métodos matemáticos usados, capacidad intuitiva humana y límites naturales a la pronosticabilidad, (Alvarado, 2014) De esos cuatro factores, tan solo uno de ellos es inmodificable y es límite que impone la naturaleza sobre la predictibilidad, que estadísticamente se conoce como ruido o error aleatorio. Respecto a los tres factores restantes siempre existirá una posibilidad de mejora la cual está atada al costo.

Una técnica que ha ganado popularidad en los últimos años es el desarrollo de pronósticos basados en la integración de dos o más métodos de pronóstico para producir un pronóstico final (Humerez, 2012). De acuerdo con (Humerez, 2012), la integración de pronósticos produce ganancias consistentes en la precisión. Con el transcurso del tiempo se ha acumulado una considerable literatura sobre esta materia. La principal conclusión es que se puede mejorar significativamente la precisión de los pronósticos por medio de la integración de varios pronósticos individuales. Según (Clemen, 1989) existen pocas dudas sobre las ventajas de la integración de pronósticos, tanto en términos de predicciones estadísticas y evaluación de las estimaciones, como cuando se integran predicciones estadísticas (algorítmicas) con predicciones subjetivas. Más aún, la integración de pronósticos reduce la varianza de los errores de pronóstico fuera de la muestra (Makridakis & Winkler, 1983).

La integración de pronósticos tiene ciertas dificultades porque tienen a mostrar informaciones contrarios en algunos casos (Alvarado, 2014). Las predicciones estadísticas evidencian patrones pero tienen problemas detectando tendencias atípicas, mientras que las estimaciones subjetivas de expertos pueden detectar falsos patrones, o incluso, cuando se tiene un conocimiento profundo del mercado o se conoce de la ocurrencia de eventos futuros, no pueden anticipar exactamente los efectos sobre el pronóstico. Investigaciones han mostrado que la integración voluntaria entre el juicio de experto y el pronóstico estadístico se hace de una forma ineficiente. (Lim & O'Connor, 1995) demostró que los expertos de mercado tienen a subestimar los pronósticos estadísticos en favor de sus propios juicios y (Goodwin & Fildes, 1999) demostraron que los expertos ignoraron el pronóstico estadístico cuando estos tenían ya una base de ajuste.

Existen diferentes métodos para la integración de pronósticos (Armstrong, 2006) hace un resumen de los métodos para reducir el error, algunos de ellos son: combinación 50/50, combinación con pesos, modelos Delphi, modelos causales, *Judgmental bootstrapping*, juicio estructurado, *damped trend*, analogías estructuradas, simulación estructurada, descomposición, segmentación, ajuste y *rule-base forecasting*. Particularmente nos centraremos en tres: la combinación, la descomposición y el ajuste. Estos tres han sido seleccionados debido a su rapidez de aplicación, sin costo (judgmental bootstrapping cuesta) y facilidad de explicación para los posibles pronosticadores, dadas las restricciones de tiempo y dinero en la multinacional química.

Combinación mecánica computador - persona (combinación): En la práctica la combinación, frecuentemente, implica un promedio simple entre el pronóstico del computador y el pronóstico de la persona con información (Goodwin, 2002). Sin embargo este promedio, puede ser ponderado de acuerdo al aporte de valor de cada uno de dichos pronósticos. Aun así, el promedio simple ha probado ser una medida adecuada cuando no se posee más información sobre la correlación entre la información usada por el computador y la usada por la persona. (Goodwin, 2002). También se puede dar combinación basada en regresiones, en donde los pesos de los pronósticos individuales se estiman mediante modelos de regresión donde la variable dependiente es el pronóstico final y las variables independientes son los pronósticos de cada parte (estadísticos y de juicio) y otras variables que se cree pueden explicar o afectar el fenómeno. En el caso concreto se evaluará el efecto de las lluvias como variable independiente adicional.

Incluir el efecto lluvias en la combinación nos lleva hablar de métodos causales de pronósticos, los cuales intentan desarrollar un modelo causa y efecto entre la demanda y otras variables tales como

las precipitaciones. En el negocio agroquímico, las ventas están sujetas a la cantidad de precipitaciones que se tienen en campo. Uno de los métodos causales es precisamente el análisis de regresión.

Descomposición: El método de descomposición se refiere al desglose multiplicativo de un problema. Los expertos dan porcentajes de ajuste al pronóstico dado por el computador y posteriormente este valor es multiplicado por el pronóstico dándose así la integración.

Este método es relevante cuando se conoce más los factores que inciden en la variable respuesta que la variable misma. (Macgregor 2001) resumió resultados de tres estudios y encontró que el MSE se redujo en un 42%. La descomposición, en este caso, puede incluir dividir la información en dos: la información histórica, que será modelada estadísticamente, y la información del negocio que será incluida de manera independiente por los expertos.

En el caso particular se intentará descomponer el pronóstico en dos elementos: el aporte histórico (medido por el computador) y el aporte de negocio (dado por el experto), tratando de evitar que éste último considere la historia como insumo y más bien modifique un pronóstico histórico- sin conocerlo- basado en la información de negocio que posea.

Ajuste de juicio con pronóstico + información (ajuste): La persona, posterior a que se le permite conocer el pronóstico del computador, y tras mostrarle la información de la serie de tiempo y aquella información que usualmente tengan disponible en su metodología usual de pronóstico decide si hace o no un ajuste adicional y con ello da un pronóstico final, y este se integra con el pronóstico del computador.

Estudios de (Elgers, May, & Murray, 1995) y (Goodwin, 2000) demostraron el MSE (error medio porcentual absoluto) de los pronósticos de los expertos fue reducido.

La literatura no presenta una comparación directa entre los tres métodos (Barrero, Alvarado, Velazquez, & Caballero, 2011).

La investigación de (Goodwin, 2000), menciona la combinación y ajuste como métodos de integración. Y afirma basado en un experimento de laboratorio, que el método de ajuste es más exitoso cuando las series tienen alto nivel de ruido debido a su efecto de suavización.

Algunos autores sugieren que la descomposición es siempre mejor, porque combinación y ajuste de algún modo le dan doble peso a la misma información (Jones & Wheeler, 2006). Sin embargo, la descomposición puede llevar a sobrecarga informativa o quitarle marcos de referencia al pronosticador humano. Por tanto no es claro si alguno de los métodos es consistentemente superior a los otros en diferentes ambientes.

El objetivo de este trabajo se centra en la necesidad de integrar la información adicional causal (factor lluvias: las precipitaciones favorecen la producción agrícola y en esa medida el uso de agroquímicos como fertilizantes, insecticidas, herbicidas, fungicida, entre otros. Pueden incluirse otras variables como estado de cartera del cliente, nivel de inventarios en el distribuidor, cantidad de semilla importada, numero de hectáreas, entre otros, sin embargo por complejidad en la recolección de datos para cada variable, se decide tomar en consideración solo el factor lluvias), el pronóstico estadístico y el pronóstico generado por el experto del negocio, mediante un método riguroso, con objeto de lograr un pronóstico de mejor calidad que apunte al menor error entre el pronóstico y la venta real. **¿Cuál sería entonces la técnica para mejorar la calidad de los**

pronósticos en el negocio agroquímicos de la multinacional química integrando las diferentes fuentes de información disponibles (humano, computador y variables causales)?

Para responder a esta pregunta, es necesario responder las siguientes subpreguntas:

¿Entre los métodos propuestos de integración hombre-computador para pronosticar demanda restringida, existe un método de integración más preciso que los otros en el contexto del negocio de agroquímicos de la multinacional química, y que sea superior a los pronósticos del computador o del hombre por aparte?

¿La inclusión de la información de lluvias agrega valor, es decir mejora aun más la calidad de los pronósticos?

¿Cuál es el impacto económico de esta mejora de la calidad de los indicadores de la multinacional?

¿Cuál sería la metodología de implementación recomendada de esa integración teniendo en cuenta las personas y los procesos de la compañía?

2. OBJETIVOS DE INVESTIGACIÓN

Los siguientes son los objetivos que orientan esta investigación:

2.1. OBJETIVO GENERAL

Desarrollar una metodología para pronosticar demanda restringida integrando el juicio humano con la capacidad algorítmica para una empresa del sector de agroquímicos.

2.2. OBJETIVOS ESPECÍFICOS

- Desarrollar un diseño de experimentos y un análisis estadístico para comparar los métodos de integración de juicio humano y pronósticos estadísticos (ajuste, combinación y descomposición) desde el punto de vista de la precisión de los pronósticos.
- Probar la hipótesis sobre si la inclusión de las lluvias es relevante para tener una mejora en la calidad de los pronósticos.
- Cuantificar el impacto económico de esta mejora de la calidad de los indicadores de la multinacional.
- Diseñar una metodología de implementación del método de integración encontrado que tenga en cuenta las personas y los procesos de la compañía desde un punto de vista gerencial.

3. JUSTIFICACIÓN Y DELIMITACIÓN DEL ESTUDIO

Desde el punto de vista académico, resulta interesante estudiar un problema del cual la literatura muestra que no se han hecho profundizaciones, y es un tema de alta aplicabilidad en la industria y relevancia desde el punto de la planificación.

Desde el punto de vista social, se ofrece la posibilidad de que este trabajo sirva de recurso bibliográfico para problemas relacionados con pronósticos de demanda restringida. En el sector

agroquímico se abre la ventana para mostrar de forma científica cómo integrar la experiencia del experto del cultivo para pronosticar con la capacidad algorítmica del computador.

Desde el punto de vista económico, lograr un pronóstico de calidad se traduce automáticamente en menores días de inventario, balanceo de stock, mayor nivel de servicio y reducción de capital de trabajo.

El estudio se orienta a la obtención de pronósticos de calidad en la unidad de negocio de agroquímicos de una multinacional química, la cual presenta altos inventarios y pérdidas de mercado. La empresa le ha dado mayor credibilidad a la opinión de los expertos pero los resultados que se tienen al momento de realizar esta investigación están muy lejanos de las metas propuestas, lo cual lleva a la empresa a mostrar interés en contemplar la integración de pronósticos estadísticos con juicio de expertos como una nueva forma de planear su demanda y en respuesta a la competitividad de mercado.

Igualmente, como es un caso de estudio de un proyecto más grande, servirá de soporte para la comprensión de fenómenos humanos en el ajuste de pronósticos.

La investigación ofrecerá una mayor comprensión sobre las ventajas y limitaciones del juicio de los expertos y el modelado matemático, así como la forma más efectiva en que pueden ser integrados.

Todo esto motiva a desarrollar una metodología de apoyo para la toma de decisiones en la planificación de la demanda.

4. MARCO TEÓRICO

A continuación se presenta una breve descripción de conceptos aplicados a esta investigación.

4.1. PRONOSTICAR

- Pronosticar es el arte y la ciencia de predecir los eventos futuros y las situaciones de estos eventos.
 - Los administradores buscan hacer estimaciones sobre el futuro con una gran incertidumbre sobre ciertos factores.
 - La búsqueda de las empresas es realizar estimaciones con respecto al futuro y tomar decisiones con conocimiento con respecto a estas estimaciones.
 - Los pronósticos se pueden manejar con base a:
 - Datos históricos para proyectar el futuro en base a modelos matemáticos.
 - Predicción del futuro subjetiva o intuitiva, influencia del sesgo cognitivo.
 - Combinación de ambas opciones
- (Chase & Aquilano, 2009)

4.2. METODOS DE PRONÓSTICO

- **La suavización exponencial.** (Pindyck, 2001) es una técnica de pronóstico de series de tiempo (promedios móviles) que pondera los datos históricos exponencialmente para que los datos más recientes tengan más peso en el promedio móvil. Con la suavización exponencial simple, el pronóstico F_t se construye con la predicción del último periodo F_{t-1} más una porción α de la

diferencia entre el valor de la demanda real del periodo anterior A_{t-1} y el pronóstico del periodo anterior F_{t-1} . En la ecuación (3) se muestra como se determina el pronóstico.

$$F_t = F_{t-1} + \alpha (A_{t-1} - F_{t-1}) \quad (3)$$

La constante de suavización α es un número entre 0 y 1 que entra multiplicando en cada pronóstico, pero cuya influencia declina exponencialmente al volverse antiguos los datos.

Una α baja da más ponderación a los datos históricos. Una α de 1 refleja un ajuste total a la demanda reciente, y los pronósticos serán las demandas reales de los periodos anteriores.

La selección de α depende de las características de la demanda. Los valores altos de α son más sensibles a las fluctuaciones en la demanda. Los valores bajos de α son más apropiados para demandas relativamente estables (sin tendencia o ciclicidad), pero con una gran cantidad de variación aleatoria.

Dentro de los modelos de suavización exponencial aplicados en SPSS se escogieron automáticamente por el modelador experto los estacionales que a continuación se describen:

Estacional Simple. Este modelo es adecuado para series con tendencia y un efecto estacional que es constante a lo largo del tiempo. Sus parámetros de suavizado son el nivel y la estación.

Aditivo de Winters. Este modelo es adecuado para las series con tendencia lineal y un efecto estacional que no depende del nivel de la serie. Sus parámetros de suavizado son el nivel, la tendencia y la estación.

Multiplicativo de Winters. Este modelo es adecuado para las series con tendencia lineal y un efecto estacional que depende del nivel de la serie. Sus parámetros de suavizado son el nivel, la tendencia y la estación.

- **Método de Pronóstico Causa – Regresión Lineal.** (Chamorro A., Caba V., & Fontalvo, 2011). Los modelos de pronóstico causal generalmente consideran algunas variables que están relacionadas con la variable que se predice. Una vez que estas variables relativas se han encontrado, se construye y utiliza un modelo estadístico para pronosticar la variable de interés. Este intento es más poderoso que los métodos de serie de tiempo que únicamente utilizan los datos históricos para pronosticar la variable. Se pueden considerar muchos factores en un análisis causal. Por ejemplo, las ventas de un producto pueden estar relacionadas con el presupuesto de publicidad de la empresa, los precios de competidores y las estrategias promocionales, o aun las tasas económicas y de desempleo. En este caso, las ventas serían llamadas variable dependiente y otras variables serían llamadas variables independientes. El trabajo del administrador es de desarrollar la mejor relación estadística entre las ventas y las variables independientes. El modelo de pronóstico causal cuantitativo más común es el análisis de regresión lineal.

$$Y_t = b_0 + b_1x_1 + \dots + b_kx_k + e_t \quad (4)$$

En la ecuación (4) se muestra la variable dependiente que se desea pronosticar Y las ventas en el periodo t. Donde: y = valor de la variable dependiente, en este caso b = coeficientes x = las variables independiente.

Supuestos del Modelo de Regresión:

Linealidad. Si no se tiene linealidad se dice que tenemos un error de especificación del modelo. En el caso de que sean varias variables independientes, la opción gráfica que permita observar desviaciones del mismo es la generación de gráficos parciales de dispersión de los residuos para cada variable independiente o contra la variable dependiente. En ellos se ha eliminado el efecto proveniente de las otras variables y así la relación que muestran es la relación neta entre las variables representadas.

Independencia de la variable aleatoria “residuos” (especialmente importante si los datos se han obtenidos siguiendo una secuencia temporal). Independencia entre los residuos mediante el estadístico de Durbin-Watson, ver ecuación (5), que toma valor 2 cuando los residuos son completamente independientes (entre 1.5 y 2.5 se considera que existe independencia), $DW < 2$ indica autocorrelación positiva y $DW > 2$ autocorrelación negativa.

$$DW = \frac{\sum_{i=1}^n (e_i - e_{i-1})^2}{\sum_{i=1}^n e_i^2}, 0 \leq DW \leq 4 \quad (5)$$

Homocedasticidad o igualdad de varianzas de los residuos y los pronósticos. Esta condición se estudia utilizando las variables: ZPRED=pronósticos tipificados y ZRESID=residuos tipificados mediante:

- El estadístico de Levene
- Una figura de dispersión de residuos contra la variable dependiente.

El supuesto de homocedasticidad implica que la variación de los residuos sea uniforme en todo el rango de valores de los pronósticos (figura sin pautas de asociación).

Normalidad de los residuos tipificados. Se puede contrastar mediante:

- La prueba de Kolmogorff-Smirnov, con figuras de normalidad de tipo Q-Q (cuantiles) o P-P (proporciones)
- Gráficamente mediante Histograma

Figura de Probabilidad Normal de tipo P-P: Representa las proporciones acumuladas de la variable esperada respecto a las proporciones acumuladas de la variable observada.

4.3. DISEÑO EXPERIMENTAL

Se entiende por diseño experimental, el proceso de planeamiento de un experimento, tal que se tomen datos apropiados con la mayor realidad posible, los cuales deben ser analizados mediante métodos estadísticos que deriven conclusiones válidas y objetivas. Se puede decir que la filosofía del diseño experimental es la obtención de información con una alta fidelidad sobre el mensaje de la naturaleza a un costo mínimo. (Chase & Aquilano, 2009)

Los diseños experimentales deben tener algunas características como:

1. **Simplicidad.** La selección de los tratamientos y la disposición experimental deberá hacerse de la forma más simple posible.
2. **Grado de precisión.** El experimento deberá tener la capacidad de medir diferencias entre tratamientos con los grados de precisión que desee el investigador. Para cumplir con este propósito se deberá partir de un diseño y un número de repeticiones adecuados.
3. **Ausencia de error sistemático.** Se debe planear un experimento con el propósito de asegurar que las unidades experimentales que reciban un tratamiento no difieran sistemáticamente de aquellas que reciben otro tratamiento, procurando de esta manera obtener una estimación no sesgada del efecto de tratamientos.
4. **Rango de validez de las conclusiones.** Este deberá ser tan amplio como sea posible. Los experimentos que contribuyen a aumentar el rango de validez del experimento son los experimentos replicados y los experimentos con estructuras factoriales.
5. **Cálculo del grado de incertidumbre.** En todo experimento existe algún grado de incertidumbre en cuanto a la validación de las conclusiones. El experimento deberá ser concebido de modo que sea posible calcular la probabilidad de obtener los resultados observados debido únicamente al azar.

4.4. CUADRADO LATINO

Un diseño especial de agrupamiento doble es el denominado cuadrado latino. Un cuadrado latino es un arreglo usado para remover la heterogeneidad del material experimental en dos direcciones en estos arreglos se requiere que el número de réplicas sea igual al número de tratamientos.

Un cuadro latino es un arreglo de t símbolos en t^2 celdas arregladas en un cuadrado de t filas y t columnas, tal que todo símbolo aparece una sola vez en cada fila y en cada columna. El término t se conoce como el orden del cuadro latino. El Cuadrado Latino se usa para eliminar dos fuentes de variabilidad extrañas. (Chase & Aquilano, 2009)

Ventajas:

1. Provee una mejor estimación del error experimental
2. Mejora la precisión
3. Hace que el experimento sea más eficiente
4. Controla dos fuentes de variación

Este diseño exige que la variación entre los niveles de la variable de bloqueo deben ser máxima (significante). Estos diseños son recomendados solamente cuando el número de tratamientos está entre cinco y doce inclusive. Con menos de cinco tratamientos los grados de libertad son insuficientes para la estimación del error experimental. Un cuadrado latino con tres tratamientos tiene solamente dos grados de libertad para estimar el error experimental, mientras que un diseño con cuatro tratamientos tiene solamente seis.

Desventajas:

Cuando el número de tratamientos es grande, se puede presentar un problema potencial debido a que el requerimiento de que el número de filas y columnas debe ser igual al número de tratamientos es más difícil de obtener. También es más probable que el supuesto de interacción sea violado.

Aleatorización:

La aleatorización en el cuadrado latino consiste en elegir un cuadrado al azar entre todos los cuadrados latinos posibles. (Fisher & A. and Yates, 1957) dan el conjunto completo de cuadrado latino desde 4x4 hasta 6x6, y muestran cuadrados hasta de tamaño 12x12. (Cochran & Cox, 1957) dan cuadrado latino de muestra desde 3x3 hasta 12x12.

5. METODOLOGÍA DE LA INVESTIGACIÓN Y DESARROLLO

La metodología describe la forma en la cual se desarrolló la investigación de campo. Inicialmente, se buscó encontrar un modelo genérico de pronósticos mediante regresiones simples que combine los juicios actuales de los expertos con los pronósticos estadísticos y posteriormente se enfocó en investigar si era posible mejorar aún más ese pronóstico utilizando un método de integración de pronósticos mediante un diseño experimental.

5.1. GENERACIÓN DE UN MODELO GENÉRICO DE PRONÓSTICOS

5.1.1. TOMA DE DATOS

Para este primer paso, se tomó una muestra de 23 productos con ciclos de vida por encima del 40% y por debajo del 60%, con mayor participación ventas, que estuvieran entre las diferentes clasificaciones de los productos de la compañía según la ANDI (Asociación Nacional de Industriales): Insecticidas, Herbicidas, Fungicidas, Coayudantes y Fertilizantes y que se vendieran en una zona específica del país. La idea era aplicar modelos de regresión para integrar los pronósticos de los expertos con pronósticos estadísticos generados por el modelador SPSS y con pronósticos de precipitaciones.

Los pronósticos de los expertos fueron recogidos mes a mes mediante las planillas de Excel usadas para la planeación de demanda y los pronósticos estadísticos fueron generados en SPSS con diferentes modelos estacionales como:

- Estacional Simple
- Multiplicativo de Winters
- Aditivo de Winters

Se utilizó el modelador experto de SPSS puesto que las investigaciones indican que elegir a juicio el modelo y los parámetros es dañino para el pronóstico. Además se buscaba excluir el juicio de cualquier persona en la compañía en la generación de los pronósticos estadísticos.

Los pronósticos de lluvias fueron obtenidos a través de la oficina de Meteorología del IDEAM (Instituto de Hidrología, Meteorología y Estudios Ambientales de Colombia). Estos son suministrados de forma cualitativa y en intervalos porcentuales, los cuales se leen comparándolos con el histórico de los últimos 30 años.

Según el meteorólogo Christian F. Euscátegui C ¹, Jefe Oficina del Servicio de Pronósticos y Alertas, la clasificación utilizada para referirse a pronósticos de lluvias es: normal (entre 10% y -10%), ligeramente por encima de lo normal (superior al promedio del mes entre 10% y 40%), moderadamente por encima de lo normal (superior al promedio del mes entre 40% y 70%) y muy por encima de lo normal (superior al promedio en más de un 70%); aplica de manera inversa cuando hay déficits.

Para el desarrollo de la investigación, se tomaron de la página del IDEAM, los boletines de predicción climática y alertas desde Enero a Septiembre de 2013 y el grupo de Modelamiento de Tiempo y Clima de la subdirección de Meteorología suministró los datos promedio de precipitación por departamento de los últimos 30 años.

En cada boletín se tiene una descripción climática por región, los productos en estudio se venden principalmente en la zona Andina (figura 4), la cual comprende los departamentos de Antioquia, Bogotá D.C, Boyacá, Caldas, Cauca, Cundinamarca, Huila, Nariño, Norte de Santander, Quindío, Risaralda, Santander, Tolima y Valle.

De los promedios climatológicos de los últimos 30 años, se calculó un promedio mensual por la zona de estudio, región Andina considerando los departamentos arriba mencionados (ver tabla 2).

Tabla 2. Promedios de Precipitaciones (mm) por la región Andina – Últimos 30 años Fuente: IDEAM, Grupo de Modelamiento de Tiempo y Clima. Subdirección de Meteorología.

	PRECIPITACION (MM)												
	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP	OCT	NOV	DIC	V. ANUAL
REGION ANDINA	81	95	125	192	214	166	148	155	184	227	187	115	157



Figura 4. Región Andina
Fuente: IDEAM, Boletines de Predicción Climática y Alertas

Las precipitaciones mensuales utilizadas en las regresiones, fueron calculadas con base en los boletines de predicción climática y alertas de enero a septiembre 2013, tomando los límites inferior y superior y hallando el promedio (ver columna “mm promedio” de la tabla 3).

¹ Agosto 12 de 2013, entrevista telefónica.

Tabla 3. Pronósticos de Precipitaciones para la Zona Andina (Enero a Septiembre 2013)

Fuente: IDEAM, Boletines de Predicción Climática y Alertas

mes	mm promedio	límite inferior	límite superior	Zona Andina
ene-13	0	89	-89	Normal
feb-13	119	104	133	ligeramente por encima de lo normal
mar-13	157	138	175	ligeramente por encima de lo normal
abr-13	0	211	-211	Normal
may-13	0	236	-236	Normal
jun-13	207	182	232	ligeramente por encima de lo normal
jul-13	185	163	208	ligeramente por encima de lo normal
ago-13	194	171	217	ligeramente por encima de lo normal
sep-13	229	202	257	ligeramente por encima de lo normal

5.1.2. TRATAMIENTO DE LOS DATOS

Debido a la poca información por producto, surgió la necesidad de agrupamiento para poder aplicar los modelos de regresión, para ello se plantearon tres situaciones:

- tomar todos los productos como un conjunto de datos,
- proponer una clasificación según bondades de regresiones individuales por producto y
- tomar conjunto de productos según clasificación ANDI (Asociación Nacional de Industriales).

Como conclusiones generales, se tiene que para todas las posibles alternativas se demuestra que ni las lluvias ni la constante resultan ser significativas para inclusión en el modelo. El menor *p*-valor para la constante fue de 0,249 y para las precipitaciones el menor fue de 0,055 ambos mayores que $\alpha = 0,05$, por lo tanto se rechaza la hipótesis nula que indica la no significancia dentro del modelo de regresión lineal. Ver Anexo 1.

Los resultados del análisis de la varianza (ANOVA) se muestran en el anexo 2, estos se proporcionan para evaluar la significación de los modelos. Cuanto mayor sea el estadístico F, mejor será la predicción mediante el modelo lineal. Si el *p*-valor asociado a F es menor a α , se rechazarán las hipótesis nulas en las que se plantea que no hay relación entre las variables. Como se muestra en el anexo, todos los modelos presentan un valor de F significativo, por lo tanto, la recta de regresión tendrá los coeficientes de las variables independientes (pronósticos expertos y/o computador) distintos de cero. Del análisis ANOVA se puede deducir que los modelos de regresión son significativos aunque ninguno de ellos incluye las lluvias como variable predictora (la cual resultó no significativa).

En la validación de supuestos de normalidad solo los Coayudantes y Fungicidas muestran cumplimiento de este supuesto, las demás clasificaciones lo violaron. La linealidad, la independencia y la Homocedasticidad se cumplieron para todos los modelos (ver Anexo 3). Cabe aclarar que los modelos presentados pretenden ser predictivos, por lo cual la violación del supuesto de normalidad no se considera importante para efectos prácticos de predicción aunque indica claramente que el modelo no es explicativo y por tanto es susceptible de mejora con más variables independientes. En general, la no normalidad se debe a datos atípicos (outliers) porque las formas

de las curvas son simétricas y con picos altos alrededor de la mediana. Ello fortalece la idea de que son los momentos atípicos causados por variables externas- y no un error fundamental en el modelo- la fuente de la no normalidad encontrada.

En cuanto a la correlación entre variables significativas, todos los modelos mostraron grado de relación entre ellas. Como se puede observar en anexo 4, todas las variables están relacionadas de forma directa casi perfecta (coeficiente de Pearson cercano a 1). El valor p es menor que 0,05 por lo tanto se afirma que existe correlación entre las variables. Ello era de esperarse, e implica que los pronósticos de experto y computador de algún modo toman en cuenta la misma información. Esta multicolinealidad hace importante que el modelo sea revisado con frecuencia, puesto que sus coeficientes son inestables.

A continuación se detallan los resultados de cada una de las tres posibles agrupaciones, para identificar cuál de ellas resulta mejor para desarrollar un modelo predictivo que permita mejorar los pronósticos.

a) Método Regresión Combinación - Sin Clasificación

Mediante una regresión lineal se combinan los pronósticos del experto, del computador y las precipitaciones, la selección del método como se introducen las variables independientes en el análisis se hizo mediante la opción de SPSS de paso sucesivos.

Es importante aclarar que el modelo genérico pretende ser predictivo, aunque no explicativo dado el tamaño de muestra. En otras palabras, buscamos que nos ayude a mejorar la predicción aunque por el bajo tamaño de muestra no se puedan extraer conclusiones explicativas. A lo largo del tiempo va a resultar de interés revisar el modelo con alguna frecuencia y, con un buen record en el tiempo, quizás intentar un modelo explicativo.

Los resultados iniciales arrojaron que tanto el pronóstico del experto como el del computador resultaron ser significativos para explicar la venta. Se volvió a correr la regresión solo considerando estos dos e incluyendo constante en la ecuación, para esta segunda corrida, los resultados arrojaron que la constante no era significativa, por lo tanto se corrió una tercera vez la regresión sin incluir la constante. Los resultados del modelo final se muestran a continuación.

En la tabla 4 se observa el coeficiente de determinación R cuadrado (R^2). Este coeficiente indica la proporción de variabilidad total de la variable venta explicada por el modelo de regresión. Es decir que 72% de la variabilidad de la venta esta explicada por la combinación del pronóstico del experto y del computador.

Tabla 4. Resumen del Modelo - Sin Clasificación

Resumen del modelo^{c,d}

Modelo	R	R cuadrado ^b	R cuadrado corregida	Error típ. de la estimación
1	,847 ^a	,718	,715	3234,82873

a. Variables predictoras: computador, experto

b. Para la regresión a través del origen (el modelo sin término de intersección), R cuadrado mide la proporción de la variabilidad de la variable dependiente explicado por la regresión a través del origen. NO SE PUEDE comparar lo anterior con la R cuadrado para los modelos que incluyen una intersección.

c. Variable dependiente: venta

d. Regresión lineal a través del origen

Tabla 5. Coeficientes - Sin Clasificación

Coeficientes ^{a, b}							
Modelo	Coeficientes no estandarizados		Coeficientes tipificados	t	Sig.	Intervalo de confianza de 95,0% para B	
	B	Error típ.	Beta			Límite inferior	Límite superior
1 experto	,283	,078	,201	3,648	,000	,130	,436
computador	,870	,070	,687	12,442	,000	,732	1,008

a. Variable dependiente: venta
b. Regresión lineal a través del origen

Se observa en la tabla 5 que el modelo sugerido tiene el mayor peso con un 87% el pronóstico del computador para predecir la venta y el pronóstico del experto tan solo participa con un 28%.

El modelo sugerido por la regresión estaría expresado por la ecuación (6):

$$\text{Venta} = 0,87 \text{ PC} + 0,283 \text{ PE} \quad (6)$$

Donde

PC: pronóstico del computador

PE pronóstico del experto

b) Regresiones Individuales - Agrupación Propuesta

Para cada producto se hizo el mismo procedimiento progresivo de correr regresiones lineales mediante pasos sucesivos, e ir eliminando las variables que el modelo mostrara no significativas.

Los resultados muestran que de los 23 productos 14 de ellos no tienen modelos de regresión lineal validos. Lo cual puede sugerir una agrupación entre estos.

Tabla 6. Resumen de Métricas para Regresiones Individuales

PROD	R	R ²	R ² COR	ERROR TÍPICO ESTI	PE	PC	LLUVIAS	CONST	SUMA DE CUADRA REG	SUMA DE CUADRA RES	MEDIA				DESVIACION TÍPICA			
											V	PC	PE	LLUVIAS	V	PC	PE	LLUVIAS
P1	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
P2	0,680	0,463	0,386	9693,25	X	-	-	-	565.971.956,68	657.714.043,32	18.400,00	1.900,78	1.042,67	-	12.367,73	891,08	938,33	-
P3	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
P4	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
P5	0,711	0,506	0,436	1596,96	-	X	-	-	48.394.786,37	47.209.611,63	5.046,67	463,11	411,44	-	3.456,96	266,98	430,95	-
P6	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
P7	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
P8	0,876	0,767	0,689	10986,71	-	X	X	X	2.381.000.000	724.200.000	21.600,00	3.418,67	2.322,78	121,22	19.701,05	3.438,14	2.065,40	95,99
P9	0,672	0,451	0,373	6367,94	-	X	-	-	233.405.204,7	283.854.684,2	9.028,89	1.731,16	802,00	-	8.040,99	839,36	801,50	-
P10	0,771	0,595	0,537	5546,79	-	X	-	-	315.888.882,3	215.368.517,7	13.920,00	1.331,22	1.285,78	-	8.149,06	490,68	752,27	-
P11	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
P12	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
P13	0,764	0,583	0,523	19506,11	-	X	-	-	3.724.099.608,2	2.663.417.614,0	48.905,56	4.642,67	3.297,22	-	26.256,67	2.564,40	3.703,74	-
P14	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
P15	0,806	0,650	0,600	1510,94	-	X	-	-	29.667.750,5	15.980.738,4	3.861,11	426,69	380,89	-	2.388,74	230,51	299,46	-
P16	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
P17	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
P18	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
P19	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
P20	0,687	0,472	0,397	57155,94	-	X	-	-	20.461.890.426	22.867.609.574	118.250,00	3.708,51	7.928,11	-	73.594,75	6.656,22	8.486,78	-
P21	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
P22	0,712	0,507	0,436	5868,51	X	-	-	-	247.854.687	241.075.868	19.222,22	2.038,11	917,78	-	7.817,69	1.543,04	884,38	-
P23	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-

También se muestra que la venta de dos productos se explica mediante el pronóstico del experto, 6 de ellos mediante el pronóstico del computador y 1 de ellos mediante el pronóstico del computador y las lluvias. Los coeficientes de determinación en promedio son del orden de 0,54 lo cual sugiere que hay una relación lineal entre las variables. Se propone entonces con base en estos resultados formar dos grupos como lo indica la figura 5.




Figura 5. Clasificación Propuesta sobre los 23 productos de estudio.

REGRESION GRUPO A

La regresión lineal muestra solo considerar el pronóstico del computador para predecir la venta. Se observa en la ANOVA (anexo 2) una significancia del modelo menor a 0,05. El coeficiente de determinación es del orden de 0,732, lo que indica que hay una fuerte relación lineal entre las variables venta y pronóstico de computador, y que el 85% de la variabilidad de la venta es explicada por el pronóstico del computador.

Tabla 7. Resumen del Modelo – Clasificación propuesta Grupo A

Resumen del modelo^{c,d}

Modelo	R	R cuadrado ^b	R cuadrado corregida	Error típ. de la estimación
1	,855 ^a	,732	,728	2693,91718

a. Variables predictoras: PC

b. Para la regresión a través del origen (el modelo sin término de intersección), R cuadrado mide la proporción de la variabilidad de la variable dependiente explicado por la regresión a través del origen. NO SE PUEDE comparar lo anterior con la R cuadrado para los modelos que incluyen una intersección.

c. Variable dependiente: VENTA

d. Regresión lineal a través del origen

Tabla 8. Coeficientes - Clasificación propuesta Grupo A

Coeficientes^{a,b}

Modelo	Coeficientes no estandarizados		Coeficientes tipificados	t	Sig.
	B	Error típ.	Beta		
1 PC	1,197	,081	,855	14,776	,000

a. Variable dependiente: VENTA

b. Regresión lineal a través del origen

Se observa en la tabla 8 que el pronóstico del computador tiende a quedarse un poco por debajo, por lo que es necesario ajustar un 19,7% hacia arriba. El modelo sugerido por la regresión estaría expresado por la ecuación (7):

$$\text{Venta} = 1,197 \text{ PC} \quad (7)$$

Donde

PC: pronóstico del computador

REGRESION GRUPO B

La variabilidad de la venta esta explicada en un 84% (ver tabla 9) por los pronósticos experto y computador. Teniendo mayor peso este último con un 82% y el experto con un 32%. Los coeficientes de determinación sugieren relación lineal entre las variables.

Tabla 9. Resumen del Modelo – Clasificación propuesta Grupo B

Resumen del modelo				
Modelo	R	R cuadrado ^b	R cuadrado corregida	Error típ. de la estimación
1	,843 ^a	,710	,706	3562,66125

a. Variables predictoras: PC, PE

b. Para la regresión a través del origen (el modelo sin término de intersección), R cuadrado mide la proporción de la variabilidad de la variable dependiente explicado por la regresión a través del origen. NO SE PUEDE comparar lo anterior con la R cuadrado para los modelos que incluyen una intersección.

Tabla 10. Coeficientes - Clasificación propuesta Grupo B

Coeficientes ^{a,b}						
Modelo		Coeficientes no estandarizados		Coeficientes tipificados	t	Sig.
		B	Error típ.	Beta		
1	PE	,323	,114	,212	2,839	,005
	PC	,819	,091	,670	8,967	,000

a. Variable dependiente: VENTA

b. Regresión lineal a través del origen

El modelo sugerido por la regresión estaría expresado por la ecuación (8):

$$\text{Venta} = 0,819 \text{ PC} + 0,323 \text{ PE} \quad (8)$$

Donde

PC: pronóstico del computador

PE: pronóstico del experto

c) Regresiones por clasificación ANDI

• INSECTICIDAS

Según la Tabla 12, se tiene que la variabilidad de la venta es explicada en casi un 93% por los pronósticos del computador y experto.

Tabla 11. Resumen del Modelo – Clasificación ANDI – Insecticidas

Resumen del modelo				
Modelo	R	R cuadrado ^b	R cuadrado corregida	Error típ. de la estimación
1	,926 ^a	,857	,850	1346,23008

a. Variables predictoras: PC, PE

b. Para la regresión a través del origen (el modelo sin término de intersección), R cuadrado mide la proporción de la variabilidad de la variable dependiente explicado por la regresión a través del origen. NO SE PUEDE comparar lo anterior con la R cuadrado para los modelos que incluyen una intersección.

Tabla 12. Coeficientes - Clasificación ANDI – Insecticidas

Coeficientes^{a,b}

Modelo	Coeficientes no estandarizados		Coeficientes tipificados	t	Sig.
	B	Error típ.	Beta		
1 PE	,310	,107	,259	2,895	,006
PC	,755	,095	,713	7,974	,000

a. Variable dependiente: VENTA

b. Regresión lineal a través del origen

Se observa en la tabla 12 los coeficientes del modelo sugerido.

El modelo sugerido por la regresión estaría expresado por la ecuación (9):

$$\text{Venta} = 0,755 \text{ PC} + 0,310 \text{ PE} \quad (9)$$

Donde

PC: pronóstico del computador

PE: pronóstico del experto

• HERBICIDAS

De la tabla 13 y 14, se puede decir que el 84% de la variabilidad de la venta está explicada por el pronóstico del computador.

Tabla 13. Resumen del Modelo – Clasificación ANDI – Herbicidas

Resumen del modelo^{c,d}

Modelo	R	R cuadrado ^b	R cuadrado corregida	Error típ. de la estimación
1	,845 ^a	,715	,708	4398,53151

a. Variables predictoras: PC

b. Para la regresión a través del origen (el modelo sin término de intersección), R cuadrado mide la proporción de la variabilidad de la variable dependiente explicado por la regresión a través del origen. NO SE PUEDE comparar lo anterior con la R cuadrado para los modelos que incluyen una intersección.

c. Variable dependiente: VENTA

d. Regresión lineal a través del origen

Tabla 14. Coeficientes - Clasificación ANDI – Herbicidas

Coeficientes^{a,b}

Modelo	Coeficientes no estandarizados		Coeficientes tipificados	t	Sig.
	B	Error típ.	Beta		
1 PC	,954	,091	,845	10,498	,000

a. Variable dependiente: VENTA

b. Regresión lineal a través del origen

Se observa en la tabla 14 los coeficientes del modelo sugerido.

El modelo sugerido por la regresión estaría expresado por la ecuación (10):

$$\text{Venta} = 0,954 \text{ PC} \quad (10)$$

Donde

PC: pronóstico del computador

- FUNGICIDAS**

El coeficiente R indica que el 88% de la variabilidad de la venta es explicada por los pronósticos de experto y computador, los cuales resultaron ser significativos, según la tabla 16.

Tabla 15. Resumen del Modelo – Clasificación ANDI – Fungicidas

Resumen del modelo ^{c,d}				
Modelo	R	R cuadrado ^b	R cuadrado corregida	Error típ. de la estimación
1	,883 ^a	,780	,769	1850,66021

a. Variables predictoras: PC, PE

b. Para la regresión a través del origen (el modelo sin término de intersección), R cuadrado mide la proporción de la variabilidad de la variable dependiente explicado por la regresión a través del origen. NO SE PUEDE comparar lo anterior con la R cuadrado para los modelos que incluyen una intersección.

c. Variable dependiente: VENTA

d. Regresión lineal a través del origen

Tabla 16. Coeficientes - Clasificación ANDI – Fungicidas

Coeficientes ^{a,b}					
Modelo	Coeficientes no estandarizados		Coeficientes tipificados	t	Sig.
	B	Error típ.	Beta		
1 PE	,307	,098	,292	3,123	,003
PC	,814	,114	,667	7,135	,000

a. Variable dependiente: VENTA

b. Regresión lineal a través del origen

Se observa en la tabla 16 los coeficientes del modelo sugerido,

El modelo sugerido por la regresión estaría expresado por la ecuación (11):

$$\text{Venta} = 0,814 \text{ PC} + 0,307 \text{ PE} \quad (11)$$

Donde

PC: pronóstico del computador

PE: pronóstico experto

- COAYUDANTES**

El coeficiente R indica que el 75% de la variabilidad de la venta es explicada por los pronósticos de experto y computador, los cuales resultaron ser significativos, según la tabla 18.

Tabla 17. Resumen del modelo – Clasificación ANDI – Coayudantes

Resumen del modelo ^{c,d}				
Modelo	R	R cuadrado ^b	R cuadrado corregida	Error típ. de la estimación
1	,748 ^a	,559	,542	1293,76739

a. Variables predictoras: PE

b. Para la regresión a través del origen (el modelo sin término de intersección), R cuadrado mide la proporción de la variabilidad de la variable dependiente explicado por la regresión a través del origen. NO SE PUEDE comparar lo anterior con la R cuadrado para los modelos que incluyen una intersección.

c. Variable dependiente: VENTA

d. Regresión lineal a través del origen

Tabla 18. Coeficientes - Clasificación ANDI – Coayudantes

Coeficientes ^{a,b}					
Modelo		Coeficientes no estandarizados		Coeficientes tipificados	Sig.
		B	Error típ.	Beta	
1	PE	1,171	,204	,748	,000

a. Variable dependiente: VENTA

b. Regresión lineal a través del origen

Se observa en la tabla 18 los coeficientes del modelo sugerido

El modelo sugerido por la regresión estaría expresado por la ecuación (12):

$$\text{Venta} = 1,171 \text{ PE} \quad (12)$$

Donde

PE: pronóstico experto

• FERTILIZANTES

El coeficiente R indica que el 84% de la variabilidad de la venta es explicada por los pronósticos de experto y computador, los cuales resultaron ser significativos, según la tabla 20.

Tabla 19. Inclusión de precipitaciones – Clasificación ANDI – Fertilizantes

Resumen del modelo ^{c,d}				
Modelo	R	R cuadrado ^b	R cuadrado corregida	Error típ. de la estimación
1	,836 ^a	,699	,693	4751,44290

a. Variables predictoras: PC

b. Para la regresión a través del origen (el modelo sin término de intersección), R cuadrado mide la proporción de la variabilidad de la variable dependiente explicado por la regresión a través del origen. NO SE PUEDE comparar lo anterior con la R cuadrado para los modelos que incluyen una intersección.

c. Variable dependiente: VENTA

d. Regresión lineal a través del origen

Tabla 20. Coeficientes - Clasificación ANDI – Fertilizantes

Coeficientes ^{a,b}					
Modelo	Coeficientes no estandarizados		Coeficientes tipificados	t	Sig.
	B	Error típ.	Beta		
1 PC	1,291	,128	,836	10,119	,000

a. Variable dependiente: VENTA

b. Regresión lineal a través del origen

Se observa en la tabla 20 los coeficientes del modelo sugerido
El modelo sugerido por la regresión estaría expresado por la ecuación (13):

$$\text{Ventas} = 1,291 \text{ PC} \quad (13)$$

Donde

PC: pronóstico del computador

5.1.3. MODELOS DE REGRESIÓN LINEAL

Finalmente se tienen los siguientes modelos de regresión para predecir la venta.

Puesto que estos modelos no cumplen a cabalidad los supuestos, y dado que buscamos un modelo predictivo y no explicativo, se decidió probarlos todos en un modelo entrenamiento-validación, en donde los modelos generados se consideran una base de entrenamiento, y van a ser probados fuera de muestra durante dos meses con datos frescos para saber cuál de ellos funciona mejor en lo que respecta a su pronosticabilidad. Los modelos predictivos están basados en las ideas que surgen de la minería de datos. para ver una discusión al respecto, capítulo 2 de Predictive Data Mining: A Practical Guide (The Morgan Kaufmann Series in Data Management Systems) by Sholom M. Weiss and Nitin Indurkha (Aug 15, 1997).

Tabla 21. Resumen modelos de regresión.

Tipo de clasificación	Regresión	Ecuación
SIN CLASIFICACIÓN	Todos los productos	Venta = 0,870 PC + 0,283 PE
CLASIFICACIÓN PROPUESTA	Grupo A	Venta = 1,197 PC
	Grupo B	Venta = 0,819 PC + 0,323 PE
CLASIFICACIÓN ANDI	Insecticidas	Venta = 0,755 PC + 0,310 PE
	Herbicidas	Venta = 0,954 PC
	Fungicidas	Venta = 0,814 PC + 0,307 PE
	Coayudantes	Venta = 1,171 PE
	Fertilizantes	Venta = 1,291 PC

5.2. APLICACIÓN DE MÉTRICAS A CADA MODELO

5.2.1. FINAL FORECAST ACCURACY & BIAS %

De las figuras 6, 7 y 8 se concluye que definitivamente cambiar la situación actual se traducirá en mejora del *Final Forecast Accuracy* y del *Bias %*. Las métricas acumuladas en el periodo enero a

septiembre del año 2013, muestran aumento mínimo del primer indicador del 32% al 72% y del segundo indicador del -33% al -8%. Escoger entre un modelo propuesto y otro, estaría determinado por aquél que arroje las mejores métricas, para el Final Forecast Accuracy el mejor modelo sería la Clasificación ANDI con un 43% de mejora y para el Bias % el mejor modelo es la Clasificación Propuesta con un 29% de mejora.




Figura 6. Modelo sin clasificación: Comparación de métricas Situación Actual vs. Propuesta (Final Forecast Accuracy – Bias %)




Figura 7. Modelo clasificación propuesta: Comparación de métricas Situación Actual vs. Propuesta (Final Forecast Accuracy – Bias %)




Figura 8. Modelo clasificación ANDI: Comparación de métricas Situación Actual vs. Propuesta (Final Forecast Accuracy – Bias %)

5.2.2. DÍAS DE INVENTARIO

Se comprueba que cambiar la situación actual mejora el DIV. Para el cálculo de los días de inventario se tomo la muestra estudiada y se proyectó el comportamiento de la métrica en el periodo de enero a septiembre de 2013. En la figura 9 se observa que el modelo sin clasificación arroja un DIV a septiembre de 100 días, 36 menos que la situación actual.




Figura 9. Modelo sin clasificación: Comparación de métricas Situación Actual vs. Propuesta (días de inventario DIV YTD)




Figura 10. Modelo clasificación propuesta: Comparación de métricas Situación Actual vs. Propuesta (días de inventario DIV YTD)




Figura 11. Modelo clasificación ANDI: Comparación de métricas Situación Actual vs. Propuesta (días de inventario DIV YTD)

5.3. MODELO ENTRENAMIENTO Y VALIDACIÓN

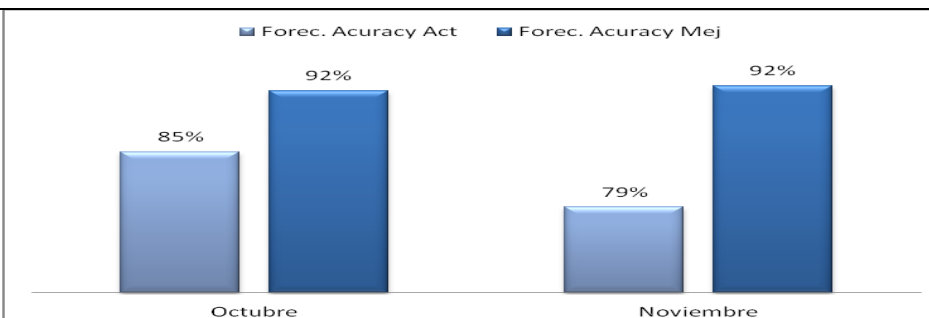
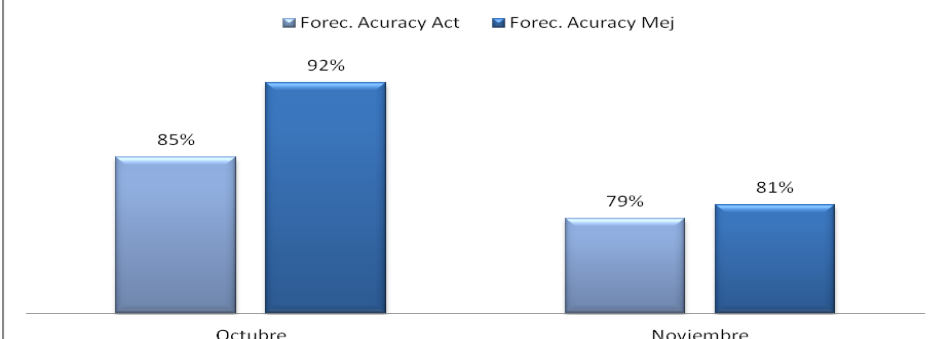
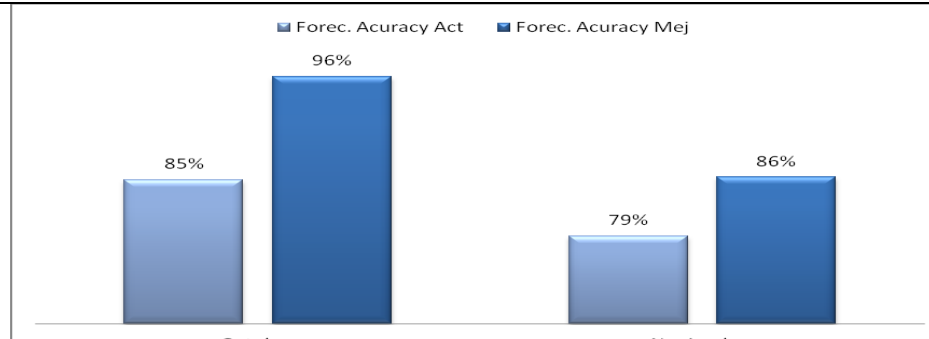
En esta sesión se evalúa la pronosticabilidad de los modelos sugeridos en un periodo de validación comprendido entre octubre y noviembre, el mes de diciembre se descarta por ser atípico. Con cualquier de las tres clasificaciones hubo mejora con los datos frescos, de la tabla 22, se puede afirmar que el modelo sin clasificación es el que arroja una mayor mejora en el *Final Forecast Accuracy*, pasando de un 85% a un 92% en el primer mes y de 79% a un 92% en el segundo mes.

Dado que en los meses de enero a septiembre, este modelo alcanzó el menor DIV (YTD) con 100 días de Inventario, que el *Final Forecast Accuracy* mejoro de un 32% a un 74% y que Bias% paso de un -33% a un -6%, se concluye que **el modelo propuesto es sin clasificación** y esta dado por la ecuación (14):

$$\text{Venta} = 0,870 \text{ PC} + 0,283 \text{ PE} \quad (14)$$

Donde el pronóstico del computador se le da un peso de un 87% y al pronóstico del experto se le da un peso del 28,3%. Estos coeficientes surgieron del mejor ajuste posible de la recta de regresión con datos frescos. Se debe precisar que estos coeficientes deberán revisarse periódicamente ya que tienden a ser inestables en el tiempo.

Tabla 22. Resumen validación de modelos meses Octubre - Noviembre

Tabla 22. Resumen validación de modelos meses Octubre - Noviembre										
Modelo Sugerido	Resultado de Final Forecast Accuracy Oct – Nov									
Sin clasificación	 <table><thead><tr><th>Mes</th><th>Forec. Accuracy Act</th><th>Forec. Accuracy Mej</th></tr></thead><tbody><tr><td>Octubre</td><td>85%</td><td>92%</td></tr><tr><td>Noviembre</td><td>79%</td><td>92%</td></tr></tbody></table>	Mes	Forec. Accuracy Act	Forec. Accuracy Mej	Octubre	85%	92%	Noviembre	79%	92%
Mes	Forec. Accuracy Act	Forec. Accuracy Mej								
Octubre	85%	92%								
Noviembre	79%	92%								
Clasificación propuesta	 <table><thead><tr><th>Mes</th><th>Forec. Accuracy Act</th><th>Forec. Accuracy Mej</th></tr></thead><tbody><tr><td>Octubre</td><td>85%</td><td>92%</td></tr><tr><td>Noviembre</td><td>79%</td><td>81%</td></tr></tbody></table>	Mes	Forec. Accuracy Act	Forec. Accuracy Mej	Octubre	85%	92%	Noviembre	79%	81%
Mes	Forec. Accuracy Act	Forec. Accuracy Mej								
Octubre	85%	92%								
Noviembre	79%	81%								
Clasificación ANDI	 <table><thead><tr><th>Mes</th><th>Forec. Accuracy Act</th><th>Forec. Accuracy Mej</th></tr></thead><tbody><tr><td>Octubre</td><td>85%</td><td>96%</td></tr><tr><td>Noviembre</td><td>79%</td><td>86%</td></tr></tbody></table>	Mes	Forec. Accuracy Act	Forec. Accuracy Mej	Octubre	85%	96%	Noviembre	79%	86%
Mes	Forec. Accuracy Act	Forec. Accuracy Mej								
Octubre	85%	96%								
Noviembre	79%	86%								

Según la tabla 21, se concluye preliminarmente que cuando el modelo toma en cuenta el computador y el experto, da un peso mayor al computador y menor al experto, casi siempre alrededor de 80% computador y 20% experto. Y ahora con los resultados de las métricas se puede decir que lo más robusto es un modelo sin clasificación 80-20.

5.4. DISEÑO EXPERIMENTAL APLICADO

Para la comparación de los tres métodos de integración (ajuste, combinación y descomposición) se plantea un **diseño experimental** en un estudio de campo (no en laboratorio), según Alvarado (2014) es la técnica más rigurosa para la realización de comparaciones entre procesos y es también la adecuada para evaluar calidad por diseño de acuerdo con el concepto de Genichi Taguchi. (Roy, 2001). Las variables incluidas en el modelo son las mencionadas y discutidas en el estado del arte, y por tanto permiten responder las preguntas planteadas en la investigación, particularmente la pregunta: ¿Entre los métodos propuestos de integración hombre-computador para pronosticar demanda restringida, existe un método de integración más preciso que los otros en el contexto del negocio de agroquímicos de la multinacional química, y que sea superior a los pronósticos del computador o del hombre por aparte?

5.4.1. VARIABLES DE RESPUESTA

Para el segundo, tercer y cuarto objetivo específico la variable de respuesta que será evaluada es la precisión y para el quinto objetivo específico el impacto económico será evaluado en términos de los indicadores de la empresa.

La **precisión** será medida a partir del error porcentual absoluto en el periodo t (APE_t), el cual se define en la ecuación (15):

Sea Y_t el resultado de la observación en el tiempo t y F_t el pronóstico generado para el tiempo t,

$$APE_t = 100 * \left| \frac{Y_t - F_t}{Y_t} \right| \quad (15)$$

Puesto que los diseños experimentales comparan los promedios de las variables de respuesta, las diferencias entre metodologías de pronóstico serán diferencias en el error absoluto porcentual promedio (MAPE) y mejoramientos de ese MAPE frente al pronóstico ingenuo y frente al pronóstico del sistema.

5.4.2. FUENTES DE VARIACIÓN

Factores:

a) Métodos de pronóstico

Este factor incluye tres niveles de comparación (descomposición, combinación y ajuste)

Pronóstico ingenuo: Un pronóstico ingenuo es aquel que pronostica el periodo t+1 con el mismo valor ocurrido durante el periodo t.

Pronóstico computador: El pronóstico del computador se generará con el modelador experto de SPSS incluyendo únicamente modelos de suavización exponencial y sin incluir la detección de atípicos. Es el tipo de pronóstico que se podría generar fácilmente en una hoja de Excel.

Pronóstico persona con información: El pronóstico de la persona le será preguntado a cada una de las personas por cada producto seleccionado, tras mostrarles la información de la serie de tiempo y aquella información que usualmente tengan disponible en su metodología usual de pronóstico.

Combinación mecánica computador - persona (combinación): Se promediarán los dos pronósticos anteriores: el pronóstico computador y el pronóstico persona con información. **La combinación será un promedio.** El promedio ha probado ser una medida adecuada cuando no se posee más información sobre la correlación entre la información usada por el computador y la usada por la persona. Goodwin (2002).

Descomposición: Se le indicará a la persona que se ha realizado un pronóstico matemático y se le indicará que tipo de información ese pronóstico debe haber modelado ya. Sin embargo, no se le dará a conocer el pronóstico como tal. Una vez explicado esto, se le pedirá si desea o no realizar un ajuste a ese pronóstico, y en caso de desearlo, basado en qué información adicional no modelada por el computador se basa para ello. Una vez dadas las explicaciones, y si el deseo es ajustar, se le pedirá que indique en el formato que desee (aditivo o multiplicativo) el valor de ese ajuste. El ajuste será integrado con el pronóstico computador.

Ajuste de juicio con pronóstico + información (ajuste): La persona, posterior a que se le permite conocer el pronóstico del computador, y tras mostrarle la información de la serie de tiempo y aquella información que usualmente tengan disponible en su metodología usual de pronóstico decide si hace o no un ajuste adicional y con ello da un pronóstico final.

La aplicación de todos los tratamientos en un mismo período para un mismo producto no es posible porque no puede hacerse de manera completamente aleatoria. El orden de recolección debería tener el ajuste en último lugar, puesto que el ajuste implica conocer el pronóstico de la máquina de antemano, lo cual arruinaría tanto la combinación -porque los inputs ya serían claramente dependientes- y la descomposición- puesto que ésta también se basa en la idea de que el aporte humano debe enfocarse en los aspectos no modelados por la máquina. Por tanto, para un período de tiempo t no podrá usar más de un método de integración para el mismo producto, porque los efectos del orden y del método quedarían confundidos. Esta restricción será tenida en cuenta en el plan general de aleatorización.

b) Producto

Un producto no necesariamente se relaciona con una referencia particular para un SKU (*stock keeping unit*), sino que corresponde a niveles de agregación que resulten de interés para la compañía de acuerdo al protocolo establecido en el numeral 6.3. Los productos a escoger no pueden ser productos nuevos pues se necesita un record histórico que permita calcular el pronóstico del computador. Así mismo los productos no deben ser de demanda intermitente, la cual obliga a metodologías de análisis diferente. El producto debe tener un horizonte de duración largo en el tiempo para permitir mediciones repetidas sobre el mismo. El factor fundamental a evaluar en el producto es la volatilidad de su serie de tiempo, la cual puede ser medida a través del coeficiente de variación. Los productos serán evaluados como un factor aleatorio, puesto que no nos interesa

particularmente el producto evaluado, sino saber si genera un efecto principal en el mejoramiento y si interactúa con el método. Los productos seleccionados de acuerdo a las características mencionadas fueron dos fungicidas y un fertilizante para los cultivos de hortalizas y flores.

- Cantus: es un fungicida que garantiza el nivel de protección contra el hongo conocido como Botrytis, el cual es muy común en muchas flores de exportación, como la rosa, clavel, crisantemo, estaticite y gypsophila. También es aplicado al cultivo de la uva.
- Cytozyme: es un fertilizante aplicado al cultivo de arroz, manzanas, melones, uvas, pimientos y papas entre otros. Es un suplemento nutricional foliar aplicado en etapas cruciales del desarrollo de los cultivos para reducir el impacto del estrés en el rendimiento y la calidad del cultivo, conduciendo a un mayor crecimiento de los cultivos.
- Forum: es una combinación de dos fungicidas para el control de una enfermedad de las plantas conocida como mildú, con acción preventiva, curativa y gran poder antiesporulante. Es absorbido y trasladado rápidamente por la planta, distribuyéndose de forma folioexpansiva. Es aplicado al cultivo de papa, melón, uva, tomate, pepino y lechuga entre otros.

Medidas repetidas:

Para cada combinación de producto-método de integración deben obtenerse réplicas para poder realizar el análisis. Dichas réplicas serán mediciones sucesivas en el tiempo del producto-método. Ello se basa en la idea de que las medidas repetidas suelen ser más eficientes que las mediciones independientes y en la necesidad de economizar sujetos. El periodo de tiempo escogido es mensual. Puesto que hay tres métodos de integración se escogerán tres personas dentro de cada empresa y se les asignará aleatoriamente el método de integración a utilizar en el mes mediante cuadrados latinos ver sección (0). Este método se aplicará independientemente para cada producto. Dado que los métodos para cada producto variarán en los meses, no es de interés proveer realimentación del error (*error feedback*) de los resultados del mes anterior. Los métodos de combinación y ajuste presentan naturalmente una realimentación de la respuesta (*outcome feedback*), pues la persona tiene acceso a los resultados del mes inmediatamente anterior, si bien no tendrá acceso a realimentación del error (*error feedback*) del mes anterior por las razones antes expuestas. No es de esperar que esta realimentación lleve a mejoramientos de aprendizaje de acuerdo con la literatura, aunque ello será sujeto de análisis del estudio y por tanto, aunque haya medidas repetidas, se puede razonablemente suponer que las mediciones son independientes.

Sujetos experimentales:

No existe evidencia en la literatura de que ciertas características en las personas influyan en la precisión de sus pronósticos. Ni siquiera la experiencia o ciertos conocimientos estadísticos fueron hallados significativos, ni tampoco la motivación, los estilos cognitivos o los roles dentro de la compañía. (Barrero, Alvarado, Velazquez, & Caballero, 2011). Sin embargo se buscará asegurar que los individuos escogidos dentro de la empresa-unidad de negocio no estén recién ingresados a la misma y que tengan conocimiento contextual de los productos que van a pronosticar y, en lo posible, que resulten afectados por los resultados del pronóstico o estén sinceramente interesados en su mejora. Así mismo se recogerán algunos datos mediante una entrevista a las personas, y así tener en cuenta explicaciones a posibles anomalías. También se probará a los sujetos.

Plan de aleatorización y recolección de datos:

Se aplicara mecanismos de aleatorización mediante cuadros latinos. Se seleccionara al azar un cuadrado estándar de 3x3. Posteriormente para cada combinación de mes-producto se harán las siguientes operaciones:

- se ordenarán al azar todos menos el primer renglón;
- se ordenarán al azar todas las columnas;
- se asignarán al azar los tratamientos a las letras, y
- el cuadrado resultante se asignará en orden a los sujetos.

5.4.3. MODELO MATEMÁTICO

El modelo matemático está basado en un diseño experimental de medidas repetidas (en el tiempo) con un factor (método) y una covariada (volatilidad del producto) para la variable de respuesta precisión en el pronóstico.

La expresión matemática del mismo se muestra en la ecuación (16):

$$Y_{ijl} = \mu + \alpha_i + \beta_j + \alpha\beta_{ij} + e_{ijl} \quad i = 1, 2, \dots, q \quad j = 1, 2, \dots, s \quad l = 1, 2, \dots, r \quad (16)$$

Donde i son los métodos aplicados, j es el producto, y l es el orden de las medidas aplicadas al sujeto.

Y_{ijl} es la medición de precisión número l del método i en el producto j . Aquí se usarán las siguientes medidas: el MAPE (ya definido) y el mejoramiento del MAPE frente al ingenuo y frente al sistema (diferencia entre el MAPE ingenuo o de sistema) y el MAPE del método; en caso de ser positivo, hay mejoras).

α_i es el efecto del i -ésimo método.

β_j es el efecto debido al j -ésimo producto.

$\alpha\beta_{ij}$ es la interacción entre el método i -ésimo y el producto j -ésimo en el tiempo.

e_{ijl} es el error experimental aleatorio en las mediciones.

5.4.4. PROTOCOLO

El protocolo para la realización del experimento es el siguiente:

a) Selección de los productos de interés: Los productos de interés serán seleccionados de acuerdo a los siguientes criterios: I) Cumplimiento de características deseables. Mediante un análisis previo de la información histórica, determinar los productos - familias de producto y niveles de agregación que cumplan con las características deseadas: sea importante en volumen o valor, no esté en arranque o finalización y no sea intermitente. II) Importancia para las personas claves de la empresa, es decir que tanto los sujetos experimentales como las personas que autoricen y estén a cargo del experimento en la compañía los consideren importantes para el desempeño de la empresa y consideren que tienen experiencia en dichos productos.

b) Conocimiento del proceso actual de pronósticos, particularmente para determinar cuándo y cómo se tendrá acceso a la información que permita calcular los resultados de la observación en el tiempo Y_t .

c) Entrevista inicial con los sujetos experimentales para mirar sus actitudes frente al pronóstico y frente a la máquina. Las preguntas de la entrevista están agrupadas en cuatro dimensiones: preguntas demográficas, preguntas relacionadas con la experticia del sujeto, preguntas relacionadas con la asimetría al evaluar los pronósticos, preguntas relacionadas con la credibilidad y aceptación de un pronóstico automático. Para medir la experticia del sujeto se utilizará una tercera persona que pueda evaluarla y para medir la credibilidad se usará una escala previamente desarrollada. En el marco teórico se definen concretamente estos conceptos de credibilidad y experticia.

d) Motivación y capacitación de las personas involucradas en el pronóstico.

e) Prueba piloto. En esta prueba se hará una revisión de todos los métodos con todos los productos para un mes específico, aclarando las dudas que puedan surgir al respecto. Después de ella se realizarán los ajustes al procedimiento, de ser necesarios.

f) Realización del pronóstico: El pronóstico en realidad va a ser un mes adelante, puesto que la información disponible va a tener un retraso de dos meses, es decir, en el mes t se dispone de la información del mes $t-1$ con el cual se hará el pronóstico del mes $t+1$. De ese modo, con la información histórica hasta el mes $t-1$ se realizan los siguientes pronósticos: 1) pronóstico ingenuo: $F_{t+1}=Y_{t-1}$ 2) pronóstico computador: se utilizará el modelador experto de SPSS con sólo modelos de suavización exponencial y sin ajustes de puntos especiales, y se le pedirá pronosticar dos meses adelante. La realización del pronóstico tiene una sintaxis de programación para garantizar su uniformidad.

g) De acuerdo con la aleatorización experimental, se toman la primera persona y el primer producto, y se observa cuál tratamiento fue asignado.

h) Si el tratamiento asignado es descomposición se le dice a la persona el guion. Se registra el resultado en la hoja de registro.

i) Si el tratamiento asignado es combinación se le entrega a la persona una pantalla de computador con la información histórica del producto de los últimos 2 años, en forma tabular y gráfica. El gráfico deberá tener una proporción 1:1,6 un tamaño de hoja completa en Excel. La tabla deberá presentarse en formato X. Posterior a ello se usa el guion. Se registra el resultado en la hoja de registro.

j) Si el tratamiento asignado es ajuste persona una pantalla de computador con la información histórica del producto de los últimos 2 años y el pronóstico realizado por el computador, en forma tabular y gráfica. El gráfico deberá tener una proporción 1:1,6 y un tamaño de hoja completa en Excel. Posterior a ello se usa el guion. Se registra el resultado en la hoja de registro.

k) Regreso al punto g, cambiando al siguiente producto. El ciclo se repite hasta tanto se terminen los productos seleccionados para cada sujeto y posteriormente se repite con cada sujetos experimental para dicho mes.

1) Con la información recopilada se alimenta la base de datos, se genera el resultado de la combinación y el pronóstico ingenuo, y se regresa el siguiente mes al punto f.

Elementos:

1. Encuesta.
2. Sintaxis de generación del pronóstico.
3. Guion.
4. Plan de aleatorización.
5. Hoja de Excel con datos históricos (tabla y gráfica) por producto
6. Hoja de Excel con datos históricos y pronóstico (tabla y gráfica) por producto
7. Hoja de Excel con información de las agregaciones de producto.
8. Hoja de registro.
9. Base de datos final en Excel.

5.4.5. RESULTADOS DEL EXPERIMENTO

No existen diferencias significativas entre los tres métodos ni a nivel de MAPE ni a nivel de mejoramiento de MAPE frente al pronóstico ingenuo estacional o frente al pronóstico del computador (valores $p > 0,2$ en los tres casos). Ver anexo 5 tablas ANOVA. El producto fue significativo a nivel del 1% únicamente en el MAPE, reflejando que el producto cytozyme foliar fue más difícil de pronosticar (ver figura 12).




Figura 12. Medias Marginales estimadas de MAPETOTAL

En el mejoramiento frente al pronóstico ingenuo, el producto fue marginalmente significativo (*valor p* < 0.05 pero mayor que 0,01) por lo que sería una evidencia débil de que los pronósticos integrados empeoraron los resultados frente al uso del ingenuo estacional para el producto cytozyme, esto puede deberse a que es relativamente nuevo en el mercado comparado con los otros dos que ya llevan más de cinco años en el mercado lo cual le permite al experto un mayor conocimiento al pronosticar (ver figura 13).




Figura 13. Medias marginales estimadas de MAPEIMPROVEMENTNAIVE

Como puede observarse en las dos siguientes tablas, no es claro que haya una mejora de los métodos frente al pronóstico ingenuo ni frente al pronóstico del sistema, puesto que los intervalos de confianza incluyen al cero entre sus valores.

Tabla 23. –Intervalos de confianza para cada método - Variable dependiente: Mejoramiento de MAPE frente a pronóstico ingenuo

METODO	Media	Error típ.	Intervalo de confianza 99%	
			Límite inferior	Límite superior
Ajuste	-17,090	30,092	-98,026	63,846
Combinación	-14,282	30,092	-95,217	66,654
Descomposición	-42,250	30,092	-123,186	38,686

Tabla 24. –Intervalos de confianza para cada método - Variable dependiente: Mejoramiento de MAPE frente a pronóstico del sistema

METODO	Media	Error típ.	Intervalo de confianza 99%	
			Límite inferior	Límite superior
A	13,614	15,719	-28,664	55,893
C	16,423	15,719	-25,855	58,701
D	-11,545	15,719	-53,824	30,733

Estos resultados muestran claramente que ninguno de los métodos de integración es superior a los demás y ninguno de ellos agregó valor al pronóstico, mientras que las regresiones si lo hicieron, por lo que no resulta de interés permitir a los expertos realizar ajustes a sus pronósticos, y una combinación por promedio simple no es suficiente para mejorar dichos pronósticos. Se hace necesario entonces usar un modelo de regresión para combinar los inputs de expertos y computador por aparte como se explicó en la sección 5.3. Aquí es importante aclarar que los ajustes son un método ampliamente usado, mientras que el uso de una fórmula de regresión requiere una implementación, la cual será explicada en la sección 7.

6. EVALUACIÓN ECONÓMICA

En la sección 5.3, se concluyó que el modelo que presenta mejora en el *Final Forecast Accuracy*, en el DIV (YTD) y en el *Bias%* sería el modelo sin clasificación (ver ecuación (17)), es decir aquel que no obedece a ningún tipo de agrupamiento, se toman todos los productos como una sola muestra.

$$\text{Venta} = 0,870 \text{ PC} + 0,283 \text{ PE} \quad (17)$$

Tabla 25. Comparativo en indicadores periodo enero - noviembre

Indicador	Modelo Actual (acumulado)	Modelo Propuesto (acumulado)
Final Forecast Accuracy	30%	72%
DIV (YTD)	138	92
Bias%	-27%	-5%




Figura 14. Comparativo en indicadores periodo enero – noviembre




Figura 15. Comparativo DIV (YTD) periodo enero – noviembre

En las figuras 14 y 15 se observa la mejora en las métricas, ahora es preciso cuantificar en términos monetarios dichas mejoras.

Cada una de los indicadores apunta a un control de inventarios por lo tanto calcular el impacto económico consiste en determinar el valor del inventario en promedio y en el cierre del periodo estudiado.

En la figura 16, se evidencia una disminución del valor del inventario en el tiempo para los 23 productos de estudio. Al finalizar el mes de noviembre se encuentra un ahorro de 2'120.478 euros. En términos de sostenimiento en promedio de inventario bajo el modelo actual se tiene 3'147.944 euros y bajo el modelo propuesto se tendría 2'303.941 euros, es decir que se tendría una disminución de 844.003 euros.




Figura 16. Valor del Inventario con Modelo Actual y Sugerido. Periodo enero – noviembre

Este ahorro sólo es considerando los 23 productos y el periodo estudiado de nueve meses del 2013, entonces implementar el modelo de combinación de pronósticos mediante regresión se traduciría en un mayor ahorro para la multinacional química.

7. METODOLOGÍA DE IMPLEMENTACIÓN

Los principios que regirán la implementación son el trabajo en equipo y la transparencia en que todas las personas involucradas en el proceso de la venta conozcan el pronóstico que servirá para la compra de mercancías.

Inicio (Solo se repite una vez en el ciclo)

- 1) Socializar los resultados de esta investigación con los directivos del negocio y del equipo de supply chain.
- 2) Definir que herramienta tecnológica será utilizada para generar los pronósticos del computador.

Primera Fase

- 3) Los productos se toman sin ninguna clasificación como una sola muestra.
- 4) Los pronósticos del computador deben ser generados con una historia de ventas mínima de 24 meses. El *frozen period* se mantendrá en dos meses.
- 5) Los pronósticos del computador serán generados en la primera semana del *frozen period*.

Segunda Fase

- 6) Los pronósticos de los expertos también deberán manejar el mismo *frozen period*, estos deben ser recogidos todos los meses mediante planillas de Excel o páginas de internet.
- 7) La información suministrada a los expertos para generar los pronósticos, deberá contener histórico de venta de los últimos 24 meses y los pronósticos dados en el mes pasado tanto en tablas como gráficamente. Esto último es importante como ayuda visual al experto que le permita ver las tendencias del producto rápidamente y así poder hacer un mejor pronóstico con toda la información que este maneja como inventarios en el distribuidor, la cartera del cliente, conocimiento del factor climático, amenazas de los competidores entre otros.
- 8) La recolección de pronósticos de los expertos debe hacerse en la última semana del mes previo al *frozen period*.
- 9) Para esta etapa es importante explicar y capacitar permanentemente a los expertos para explicarles porque no se toma directamente su pronóstico y porque deben evitar tratar de jugar a adivinar que va a hacer el computador para ellos corregirlo. Entre otras cosas, que si ellos empiezan a cambiar, las regresiones también cambiarán, por lo que es inútil tratar de jugar con las regresiones, y es mucho mejor trabajar en equipo y concentrarse en hacer el pronóstico más adecuado que puedan.

Tercera Fase

- 10) Una vez se tengan los pronósticos del computador, se combinarán con los pronósticos de los expertos mediante el modelo propuesto, este proceso se puede realizar en una tabla de Excel y deberá hacerse en la primera semana del *frozen period*.

Cuarta Fase

- 11) Luego se comunicarán a las directivas de marketing y ventas el valor de la venta y la cantidad de unidades de los próximos 24 meses. Esta reunión podrá establecerse para el día 8 hábil de cada mes, es decir la segunda semana previa a la generación de los pronósticos del computador (ver numeral 5) e integración de pronósticos (ver numeral 10). Para esta reunión se precisa hacer el desglose del 20% de los productos que hacen el 80% de la venta, de tal forma que se puedan tomar acciones.

Quinta Fase

- 12) En la reunión con ventas y marketing deberá mostrarse el comparativo tanto en valor como en unidades, el nivel de ventas considerando solo pronósticos del experto e integrado con el computador. Esto para asegurar la transparencia en el proceso, más no implica que se cambien los pronósticos.

Sexta Fase (se repita cada tres meses)

- 13) Cada tres meses deberá evaluarse el modelo predictor, mediante generación de regresiones lineales con ampliación del tamaño de muestra inicial y de acuerdo a los resultados obtenidos.

Para reforzar el trabajo en equipo, sería conveniente que el equipo de supply chain fuera también evaluado por el resultado de la venta, ya que con esta nueva metodología ellos serán los responsables de asegurar el inventario para la venta que resulte de combinar cifras duras con las predicciones de los expertos. Hoy en día, solo se asegura inventario acorde con las predicciones de los expertos y uno de los indicadores de inventario (DIV: días de inventario) es meta para ambos equipos.

En figura 17, se puede observar gráficamente esta metodología de implementación.

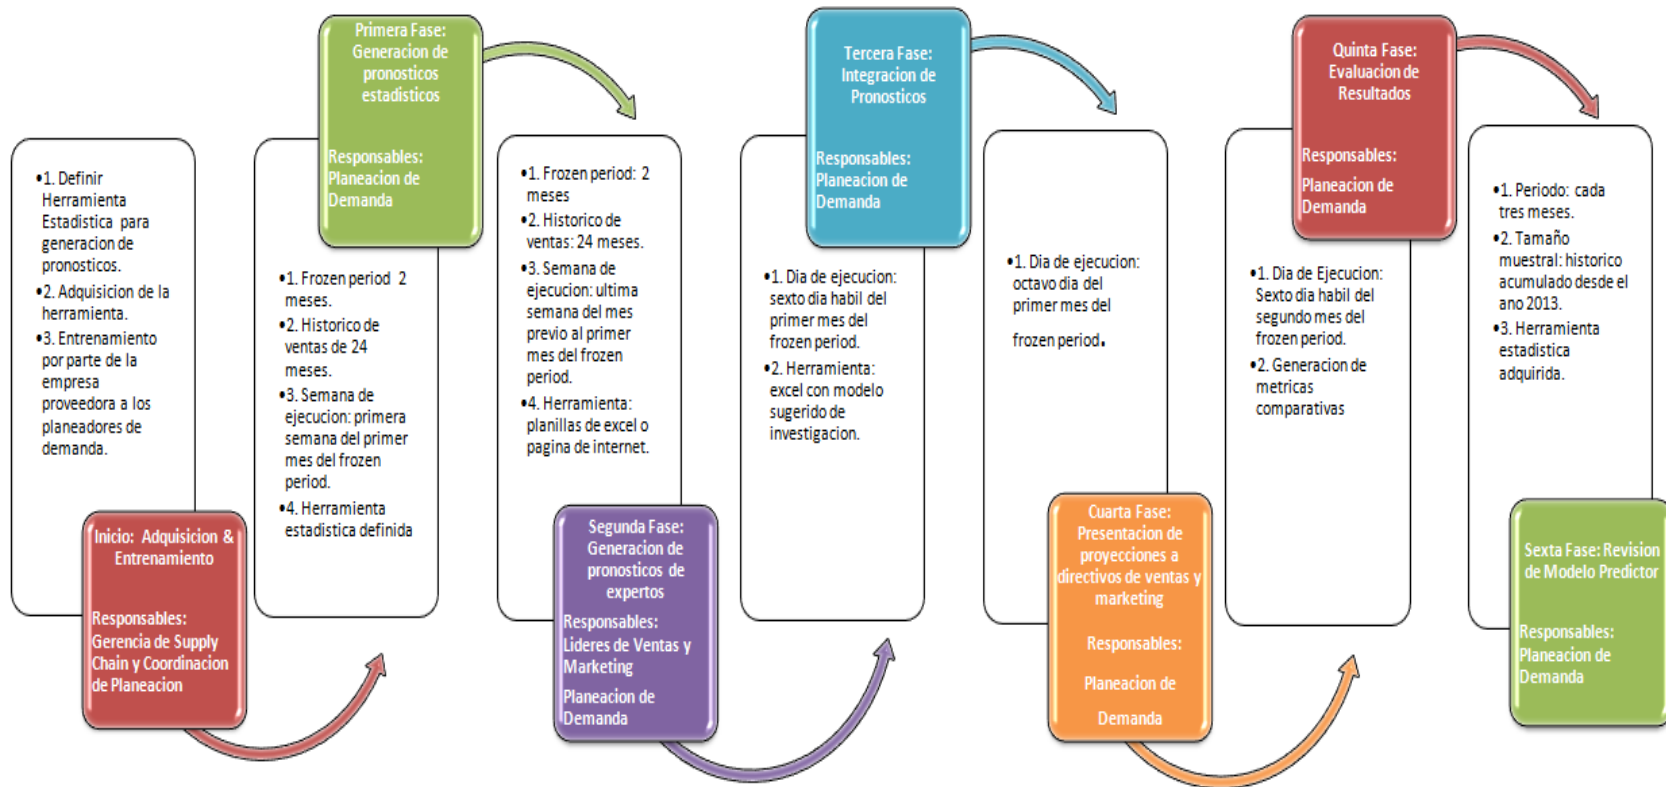


Figura 17. Metodología de implementación para la elaboración de pronósticos

8. CONCLUSIONES

En la sesión 1.2, se había planteado la pregunta siguiente:

¿Cuál sería entonces la técnica para mejorar la calidad de los pronósticos en el negocio agroquímicos de la multinacional química integrando las diferentes fuentes de información disponibles (humano, computador y variables causales)?

De la investigación realizada se concluye que definitivamente integrar el pronóstico del experto con el pronóstico del computador si contribuye a mejorar la calidad del pronóstico de ventas. Y el mejor método de integración es la combinación con pesos diferentes para cada pronóstico. Esto sería la conclusión principal además de:

- ✓ La inclusión de la información de lluvias no resulta ser significativa para predecir la venta, más allá, de esta conclusión, cabe pensar porque este resultado, aquí hay más: una alta correlación con los pronósticos ya hechos (que incluyen la estacionalidad) debido a que los expertos del mercado reconocen la dependencia de la venta de estos agroquímicos con las condiciones climáticas y el modelo de pronósticos, al ser estacional, de algún modo también ya está teniendo en cuenta el tema climático.

Por otro lado, en el año 2013 las predicciones por parte del IDEAM no fueron acertadas, se esperaban dos épocas de lluvias fuertes de febrero a marzo y de junio a septiembre y tan solo se presentaron dos semanas de intensas lluvias en ambas épocas. Esto nos lleva a concluir, que la información de lluvias utilizada podría ser validada con otra entidad privada e interesada en este tipo de datos. La multinacional química ha empezado en la altillanura colombiana a tomar datos de precipitaciones esperando poder trabajar con estos en modelos predictores de clima.

Es posible que los pronósticos climáticos utilizados no tengan la suficiente validez o que sea apropiada la inclusión de otras variables como condiciones de cartera de los clientes, inventarios en el canal de venta, estado del ciclo de vida del producto, entre otros.

En definitiva, hoy en día es un verdadero desafío predecir la condición climática, mas aun para Colombia que es un país totalmente vulnerable a estos (sequías, inundaciones, entre otros).

- ✓ La metodología propuesta es considerar todos los productos y no aplicarles ninguna clasificación, el modelo propuesto para combinar el pronóstico del experto y del computador etaria determinado por la ecuación (18)

$$\text{Venta} = 0,870 \text{ PC} + 0,283 \text{ PE} \quad (18)$$

Este modelo sugiere entonces darle mayor peso al pronósticos del computador y menor al pronóstico del experto. Los coeficientes son inestables en el tiempo, por lo cual se recomienda hacer revisión del modelo de regresión cada tres meses con su respectiva comprobación de supuestos y análisis de ANOVA.

- ✓ En la validación del modelo propuesto con los 23 productos en el periodo de enero a noviembre se encontró un ahorro de 2'120.941 euros. También se detecto que en promedio mensual el valor del inventario disminuiría en 844.003 euros.

BIBLIOGRAFIA CONSULTADA

- Alvarado, J. A. (2014). *Human-Computer Cooperation in Demand Forecasting*. Bogota: Universidad Javeriana.
- Armstrong, J. S. (2006). *Findings from evidence-based forecasting: Methods for reducing forecast error*. Elsevier, 583-598.
- Barrero, L., Alvarado, J. A., Velazquez, C., & Caballero, J. P. (2011). *Human computer interaction in forecasting*. 31st International Symposium on Forecasting. Prague, Czech Republic.
- Chamorro A., O., Caba V., N., & Fontalvo, T. J. (2011). *Gestión de la Producción y Operaciones*. Corporación para la Gestión del Conocimiento Asesores del 2000.
- Chase, R., & Aquilano, N. (2009). *Administración de Operaciones: Producción y Cadenas de Suministros* (12 ed.). Mexico: MCGRAW-HILL / INTERAMERICANA DE MEXICO.
- Clemen, R. T. (1989). *Combining forecasting: A review and annotated bibliography*. International Journal of Forecasting(55), 559-583.
- Cochran, W. G., & Cox, G. M. (1957). *Experimental designs* (Vol. 2nd Edition). New York: Wiley.
- Elgers, P. T., May, H. L., & Murray, D. (1995). *Note on adjustments to analysts' earnings forecasts based upon systematic cross-sectional components of prior-period errors*. Management Science(41), 1392-1396.
- Fisher, R. A., & Yates, F. (1957). *Statistical Tables for Biological*. Agricultural and Medical Research.
- Fowlkes, W. Y., & Creveling, C. M. (1995). *Engineering Methods for Robust Product Design: Using Taguchi Methods in Technology and Product Development*. Reading MA.: Addison-Wesley Publishing Company.
- Goodwin, P. (2000). *Correct or Combine? Mechanically integrating judgmental forecasts with statistical methods*. International Journal of Forecasting(16), 261-275.
- Goodwin, P. (2002). *Integrating management judgment and statistical methods to improve short-term forecast*. Omega-International Journal of Management Science(30(2)), 127-135.
- Goodwin, P., & Fildes, R. (1999). *Judgmental forecasts of time series affected by special events: does providing a statistical forecast improve accuracy*. Journal of Behavioral Decision Making(12), 37-53.
- Hanke, J. E., & Wichem, D. W. (2006). *Pronósticos en los negocios*. En J. E. Hanke, & D. W. Wichem, Pronósticos en los negocios (págs. 1-12, 78-81). Mexico: Editorial Pearson Prentice Hall.
- Humerez, J. (2012). *Combinación de Pronósticos: Una aplicación a la Inflación de Bolivia*. Revista de Analisis, 16, 70.
- Jones, D. R., & Wheeler, P. (2006). *Understanding and attenuating decision bias in the use of model advice and other relevant information*. Decision Support Systems, 42(3), 1917-1930.
- Lawrence, M. P., Goodwin, M., O'Connor, M., & Onkal, D. (2006). *Judgmental forecasting: a review of progress over the last 25 years*. International Journal of Forecasting(22), 493-518.
- Lim, J., & O'Connor, M. (1995). *Judgmental adjustment of initial forecasts - its effectiveness and biases*. Journal of Behavioral Decision Making(8), 149-168.
- Logistec. (25 de Abril de 2013). *Obtenido de <http://revistalogistec.com/index.php/supply-chain-management/380-estrategia-logistica/1236-planificacion-de-la-demanda-factor-clave-para-una-logistica-eficiente>*
- Macgregor, D. G. (2001). "Decomposition for judgmental forecasting and estimation," in J. S. Armstrong (ed.), *Principles of Forecasting*. Boston: Kluwer Academic Publishers.
- Makridakis, S., & Winkler, R. L. (1983). *Averages of Forecasts: Some Empirical Results*. Management Science(29), 987-996.
- Pindyck, R. (2001). *Econometría y modelos de pronóstico*. Mexico: Editorial Mc Graw Hill.
- Roy, R. (2001). *Design of experiments using the Taguchi approach: 16 steps to product and process improvement*. John Wiley & Sons.
- Sanders, N. R. (1997). *The Status of Forecasting in Manufacturing Firms*. Production & Inventory Management Journal, 38(2), 32-36.
- Sanders, N. R., & Manrodt, K. B. (1994). *Forecasting Practices in US Corporations: Survey Results*. Interfaces, 24(2), 92-100.

- Sanders, N. R., & Manrodt, K. B. (2003). The efficacy of using judgmental versus quantitative forecasting methods in practice. Omega, 31(6), 511-522.*
- Techopedia. (28 de October de 2013). Obtenido de <http://www.techopedia.com/definition/13791/demand-planning>*
- Weiss, S. M., & Indurkha, N. (1997). Predictive Data Mining: A Practical Guide (The Morgan Kaufmann Series in Data Management Systems). San Francisco: Morgan Kaufmann Publisher, Inc.*

ANEXO 1. INCLUSIÓN DE PRECIPITACIONES PARA CADA UNO DE LOS MODELOS

Se demuestra que la variable lluvias ni la constante son significativas para incluirlas en ningún modelo.

Modelo	Significancia de Coeficientes							Significancia de Coeficientes							
Sin Clasificación	Coeficientes ^a						Insecticidas	Coeficientes ^a							
	Modelo	Coeficientes no estandarizados		Coeficientes tipificados	t	Sig.		Modelo	Coeficientes no estandarizados		Coeficientes tipificados	t	Sig.		
		B	Error tip.	Beta					B	Error tip.	Beta				
	1	(Constante)	314,296	404,087		,778		,438	1	(Constante)	-355,991	368,762		-,965	,340
		experto	,274	,080	,198	3,410		,001		PE	,263	,111	,228	2,373	,022
		computador	,843	,075	,641	11,247		,000		PC	,779	,103	,722	7,595	,000
		LLUVIAS	-,322	2,544	-,006	-,127		,899		LLUVIAS	3,456	2,290	,107	1,509	,139
a. Variable dependiente: venta							a. Variable dependiente: VENTA								
Grupo A	Coeficientes ^a						Herbicidas	Coeficientes ^a							
	Modelo	Coeficientes no estandarizados		Coeficientes tipificados	t	Sig.		Modelo	Coeficientes no estandarizados		Coeficientes tipificados	t	Sig.		
		B	Error tip.	Beta					B	Error tip.	Beta				
	1	(Constante)	-12,652	542,510		-,023		,981	1	(Constante)	418,698	1248,699		,335	,739
		PC	1,084	,141	,682	7,685		,000		PC	,816	,150	,682	5,433	,000
		LLUVIAS	-1,974	3,313	-,042	-,596		,553		PE	,310	,253	,158	1,225	,228
		PE	,195	,100	,172	1,946		,055		LLUVIAS	-3,943	7,904	-,051	-,499	,621
a. Variable dependiente: VENTA							a. Variable dependiente: VENTA								
Grupo B	Coeficientes ^a						Fungicidas	Coeficientes ^a							
	Modelo	Coeficientes no estandarizados		Coeficientes tipificados	t	Sig.		Modelo	Coeficientes no estandarizados		Coeficientes tipificados	t	Sig.		
		B	Error tip.	Beta					B	Error tip.	Beta				
	1	(Constante)	414,300	571,377		,725		,470	1	(Constante)	228,679	533,085		,429	,670
		PE	,295	,122	,192	2,406		,018		PE	,273	,105	,296	2,604	,013
		PC	,793	,097	,638	8,200		,000		PC	,742	,139	,588	5,353	,000
		LLUVIAS	,108	3,694	,002	,029		,977		LLUVIAS	1,561	3,201	,051	,488	,628
a. Variable dependiente: VENTA							a. Variable dependiente: VENTA								

ANEXO 1. Continuación: INCLUSIÓN DE PRECIPITACIONES PARA CADA UNO DE LOS MODELOS.

Se demuestra que la variable lluvias ni la constante son significativas para incluirlas en ningún modelo.

Modelo	Significancia de Coeficientes						Significancia de Coeficientes						
Coayudantes	Coeficientes ^a					Fertilizantes	Coeficientes ^a						
	Modelo	Coeficientes no estandarizados		Coeficientes tipificados	t		Sig.	Modelo	Coeficientes no estandarizados		Coeficientes tipificados	t	Sig.
		B	Error típ.	Beta					B	Error típ.	Beta		
	1 (Constante)	-330,640	1044,691		-,316		,754	1 (Constante)	1435,184	1253,139		1,145	,259
	PE	,667	,337	,403	1,978		,060	PC	1,101	,279	,694	3,941	,000
	LLUVIAS	3,982	6,472	,125	,615		,544	LLUVIAS	-3,434	8,247	-,045	-,416	,679
	PC	,329	,250	,247	1,317		,201	PE	,084	,210	,069	,399	,692
a. Variable dependiente: VENTA						a. Variable dependiente: VENTA							

ANEXO 2. ANALISIS ANOVA PARA LAS REGRESIONES LINEALES

Todos los modelos presentan sig < 0.05 por lo tanto son significativos

Modelo	Análisis ANOVA							Análisis ANOVA							
Sin Clasificación	ANOVA ^{c,d}						Insecticidas	ANOVA ^{c,d}							
			Suma de cuadrados	gl	Media cuadrática	F		Sig.			Suma de cuadrados	gl	Media cuadrática	F	Sig.
	1	Regresión	5,454E9	2	2,727E9	260,588		,000 ^a	1	Regresión	4,655E8	2	2,328E8	128,437	,000 ^a
		Residual	2,145E9	205	10464116,93					Residual	77930423,98	43	1812335,441		
		Total	7,599E9	207						Total	5,435E8	45			
a. Variables predictoras: computador, experto b. Esta suma de cuadrados total no se ha corregido para la constante porque la constante es cero para la regresión a través del origen. c. Variable dependiente: venta d. Regresión lineal a través del origen								a. Variables predictoras: PC, PE b. Esta suma de cuadrados total no se ha corregido para la constante porque la constante es cero para la regresión a través del origen. c. Variable dependiente: VENTA d. Regresión lineal a través del origen							
Grupo A	ANOVA ^{c,d}						Herbicidas	ANOVA ^{c,d}							
			Suma de cuadrados	gl	Media cuadrática	F		Sig.			Suma de cuadrados	gl	Media cuadrática	F	Sig.
	1	Regresión	1,585E9	1	1,585E9	218,339		,000 ^a	1	Regresión	2,132E9	1	2,132E9	110,213	,000 ^a
		Residual	5,806E8	80	7257189,779					Residual	8,513E8	44	19347079,48		
		Total	2,165E9	81						Total	2,984E9	45			
a. Variables predictoras: PC b. Esta suma de cuadrados total no se ha corregido para la constante porque la constante es cero para la regresión a través del origen. c. Variable dependiente: VENTA d. Regresión lineal a través del origen								a. Variables predictoras: PC b. Esta suma de cuadrados total no se ha corregido para la constante porque la constante es cero para la regresión a través del origen. c. Variable dependiente: VENTA d. Regresión lineal a través del origen							
Grupo B	ANOVA ^{c,d}						Fertilizantes	ANOVA ^{c,d}							
			Suma de cuadrados	gl	Media cuadrática	F		Sig.			Suma de cuadrados	gl	Media cuadrática	F	Sig.
	1	Regresión	3,860E9	2	1,930E9	152,050		,000 ^a	1	Regresión	5,209E8	2	2,604E8	76,040	,000 ^a
		Residual	1,574E9	124	12692555,16					Residual	1,473E8	43	3424943,220		
		Total	5,434E9	126						Total	6,681E8	45			
a. Variables predictoras: PC, PE b. Esta suma de cuadrados total no se ha corregido para la constante porque la constante es cero para la regresión a través del origen. c. Variable dependiente: VENTA d. Regresión lineal a través del origen								a. Variables predictoras: PC, PE b. Esta suma de cuadrados total no se ha corregido para la constante porque la constante es cero para la regresión a través del origen. c. Variable dependiente: VENTA d. Regresión lineal a través del origen							

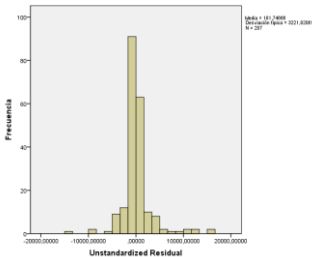
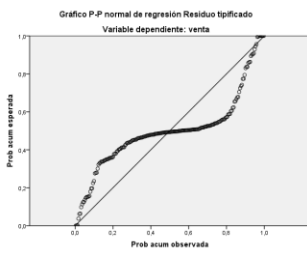
ANEXO 2. Continuación; ANALISIS ANOVA PARA LAS REGRESIONES LINEALES

Todos los modelos presentan sig < 0.05 por lo tanto son significativos

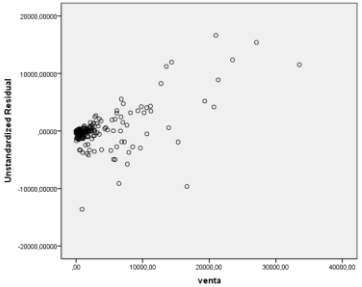
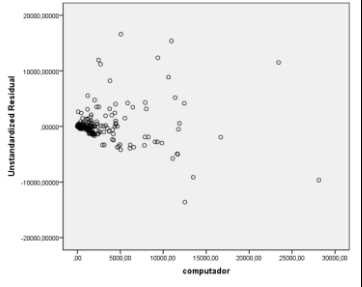
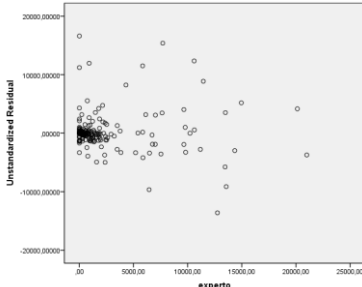
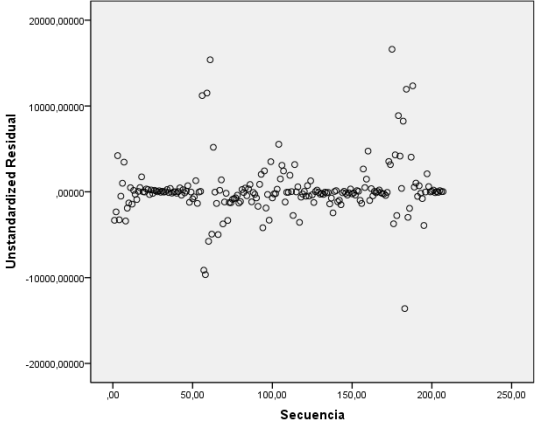
Modelo	Análisis ANOVA							Análisis ANOVA					
Coayudantes	ANOVA ^{c,d}						Fertilizantes	ANOVA ^{c,d}					
	Modelo	Suma de cuadrados	gl	Media cuadrática	F	Sig.		Modelo	Suma de cuadrados	gl	Media cuadrática	F	Sig.
	1 Regresión	55251026,27	1	55251026,27	33,009	,000 ^a		1 Regresión	2,311E9	1	2,311E9	102,386	,000 ^a
	Residual	43519685,72	26	1673834,066				Residual	9,934E8	44	22576209,67		
	Total	98770712,00	27					Total	3,305E9	45			
	a. Variables predictoras: PE b. Esta suma de cuadrados total no se ha corregido para la constante porque la constante es cero para la regresión a través del origen. c. Variable dependiente: VENTA d. Regresión lineal a través del origen							a. Variables predictoras: PC b. Esta suma de cuadrados total no se ha corregido para la constante porque la constante es cero para la regresión a través del origen. c. Variable dependiente: VENTA d. Regresión lineal a través del origen					

ANEXO 3. VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – SIN CLASIFICACION

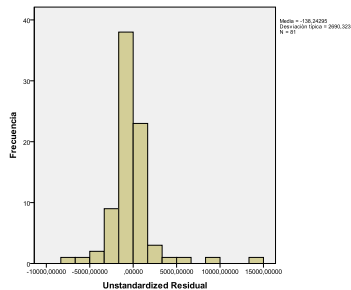
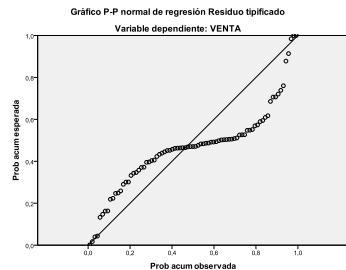
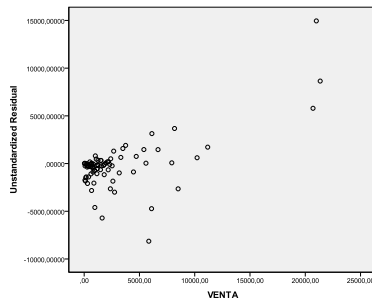
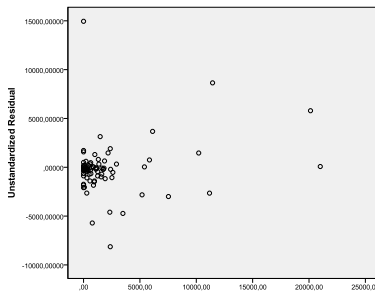
La validación permite obtener información acerca de la adecuación de los datos a los supuestos del modelo de regresión lineal. Un cumplimiento razonable de dichos supuestos garantiza que las inferencias a la población son válidas. Las herramientas de las que se dispone en SPSS para evaluar los supuestos de linealidad, normalidad, homocedasticidad e independencia de errores son tanto de naturaleza gráfica como analítica.

NORMALIDAD	Análisis 1: Histograma de los residuos	Análisis 2: Normal probability plot	Análisis 3: Test de Bondad de Ajuste. Prueba de Kolmogorov-Smirnov para una muestra (residuos no estandarizados).																								
Las figuras Histograma de residuos y figura P-P normal de regresión permiten valorar el alejamiento del supuesto de normalidad. Comparando la curva normal con la distribución empírica en el histograma y evaluando el alejamiento de los puntos representados en la segunda figura con respecto a la diagonal. Se puede concluir que existen grandes desviaciones frente a la curva normal, aunque la forma de la gráfica es simétrica como la de una curva normal. Muy probablemente los datos extremos son quienes generan esta desviación. La implicación directa es que el modelo, aunque tenga alguna capacidad predictiva, no es explicativo y es necesario en el futuro buscar más variables que pudiesen ser incluidas en el mismo No obstante, para ser más precisos se puede utilizar la prueba de Kolmogorov del menú de pruebas no paramétricas para evaluar este supuesto. Se corrobora con un sig. casi cercano a cero que no se cumple el supuesto de normalidad.			<table><tr><th colspan="2">Prueba de Kolmogorov-Smirnov para una muestra^a</th></tr><tr><th></th><th>Unstandarizad Residual</th></tr><tr><td>N</td><td>207</td></tr><tr><td>Parámetros normales^{a,b}</td><td></td></tr><tr><td>Media</td><td>181,7466567</td></tr><tr><td>Desviación típica</td><td>3221,820612</td></tr><tr><td>Diferencias más extremas</td><td></td></tr><tr><td>Absoluta</td><td>,255</td></tr><tr><td>Positiva</td><td>,255</td></tr><tr><td>Negativa</td><td>-,182</td></tr><tr><td>Z de Kolmogorov-Smirnov</td><td>3,665</td></tr><tr><td>Sig. asímtot. (bilateral)</td><td>,000</td></tr></table> <p>^a. La distribución de contraste es la Normal. ^b. Se han calculado a partir de los datos.</p>	Prueba de Kolmogorov-Smirnov para una muestra ^a			Unstandarizad Residual	N	207	Parámetros normales ^{a,b}		Media	181,7466567	Desviación típica	3221,820612	Diferencias más extremas		Absoluta	,255	Positiva	,255	Negativa	-,182	Z de Kolmogorov-Smirnov	3,665	Sig. asímtot. (bilateral)	,000
Prueba de Kolmogorov-Smirnov para una muestra ^a																											
	Unstandarizad Residual																										
N	207																										
Parámetros normales ^{a,b}																											
Media	181,7466567																										
Desviación típica	3221,820612																										
Diferencias más extremas																											
Absoluta	,255																										
Positiva	,255																										
Negativa	-,182																										
Z de Kolmogorov-Smirnov	3,665																										
Sig. asímtot. (bilateral)	,000																										

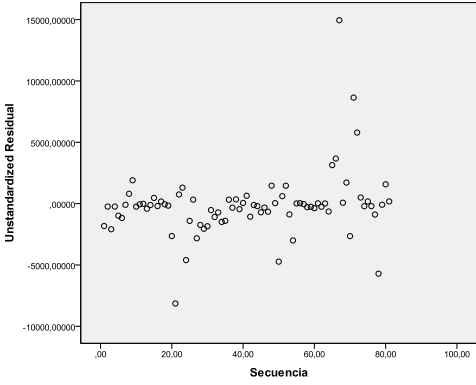
ANEXO 3. Continuación: VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – SIN CLASIFICACION

LINEALIDAD Y HOMOGENEIDAD DE VARIANZAS	Análisis 1. Figura de dispersión entre la variable venta y los residuos	Análisis 2. Figura de dispersión entre los residuos y el computador	Análisis 3. Figura de dispersión entre los residuos y el experto
<p>La figura más valiosa para evaluar incumplimientos de los supuestos: la figura de dispersión de residuos frente a puntuaciones ajustadas. Con esta figura se puede evaluar errores en la especificación del modelo por incumplimiento del supuesto de linealidad. En la medida en que aparezcan tendencias curvilíneas en la figura, el modelo utilizado sería incorrecto.</p> <p>En este caso no se observan ni curvaturas que hagan sospechar que el supuesto de linealidad es incorrecto ni incrementos o decrementos grandes de variabilidad.</p> <p>En consecuencia se puede considerar validas las conclusiones obtenidas del modelo de regresión utilizado para estudiar la relación entre las variables.</p> <p>Para la homogeneidad de varianzas se utilizan las mismas figuras, si se observa algún patrón puede significar que no existe homoestecidad.</p>			
INDEPENDENCIA	Análisis 1: Figura de los residuos contra secuencia de toma de datos		
<p>El supuesto de independencia de los residuos, se puede chequear gráficamente por medio de un diagrama de dispersión entre los residuales y el orden en que se tomaron las observaciones, si no se observa un patrón característico, indicara que los residuos se encuentran independientes o aleatoriamente distribuidos.</p>			

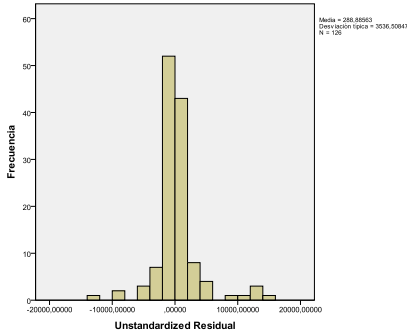
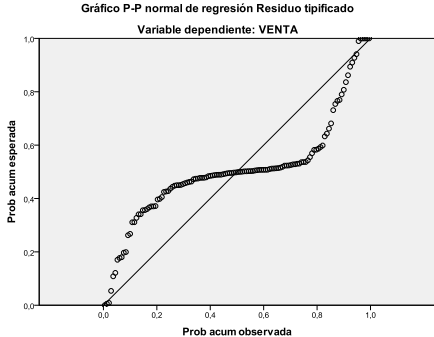
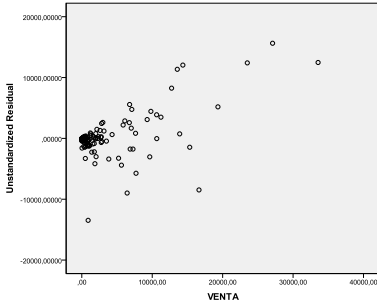
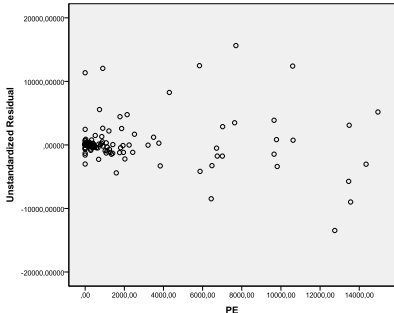
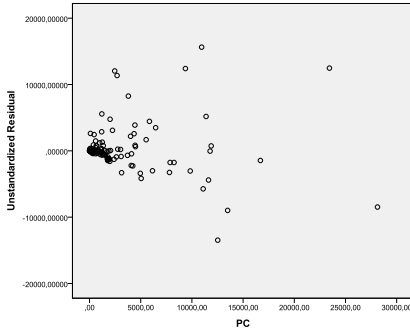
ANEXO 3. VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – GRUPO A

NORMALIDAD	Análisis 1: Histograma de los residuos	Análisis 2: Normal probability plot	Análisis 3: Test de Bondad de Ajuste. Prueba de Kolmogorov-Smirnov para una muestra (residuos no estandarizados).																								
Se corrobora con un sig. casi cercano a cero que no se cumple el supuesto de normalidad			<div>Prueba de Kolmogorov-Smirnov para una muestra</div> <table><tr><td colspan="2"></td><td>Unstandardiz ed Residual</td></tr><tr><td>N</td><td></td><td>81</td></tr><tr><td rowspan="2">Parámetros normales^{a, b}</td><td>Media</td><td>-138,2429496</td></tr><tr><td>Desviación típica</td><td>2690,323359</td></tr><tr><td rowspan="3">Diferencias más extremas</td><td>Absoluta</td><td>,227</td></tr><tr><td>Positiva</td><td>,227</td></tr><tr><td>Negativa</td><td>-,154</td></tr><tr><td>Z de Kolmogorov-Smirnov</td><td></td><td>2,045</td></tr><tr><td>Sig. asintót. (bilateral)</td><td></td><td>,000</td></tr></table> <div>a. La distribución de contraste es la Normal. b. Se han calculado a partir de los datos.</div>			Unstandardiz ed Residual	N		81	Parámetros normales ^{a, b}	Media	-138,2429496	Desviación típica	2690,323359	Diferencias más extremas	Absoluta	,227	Positiva	,227	Negativa	-,154	Z de Kolmogorov-Smirnov		2,045	Sig. asintót. (bilateral)		,000
		Unstandardiz ed Residual																									
N		81																									
Parámetros normales ^{a, b}	Media	-138,2429496																									
	Desviación típica	2690,323359																									
Diferencias más extremas	Absoluta	,227																									
	Positiva	,227																									
	Negativa	-,154																									
Z de Kolmogorov-Smirnov		2,045																									
Sig. asintót. (bilateral)		,000																									
LINEALIDAD Y HOMOGENEIDAD DE VARIANZAS	Análisis 1. Figura de dispersión entre la variable venta y los residuos	Análisis 2. Figura de dispersión entre los residuos y el experto																									
Se corrobora lineabilidad y la homostecidad de los residuos, no se identifica ningún patrón en las figuras.																											

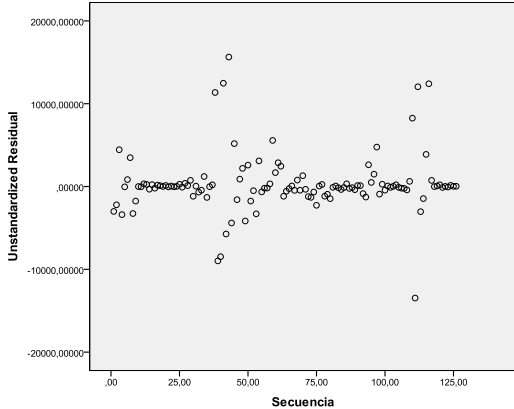
ANEXO 3. Continuación: VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – GRUPO A

INDEPENDENCIA	Análisis 1: Figura de los residuos contra secuencia de toma de datos
<p>Se corrobora independencia de los residuos, no se observa ningún patrón definido en la figura.</p>	

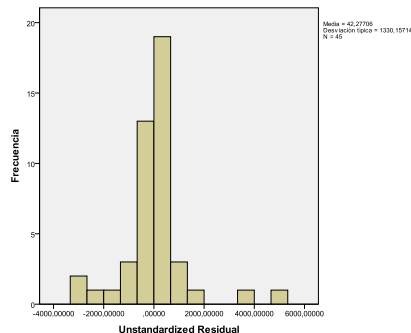
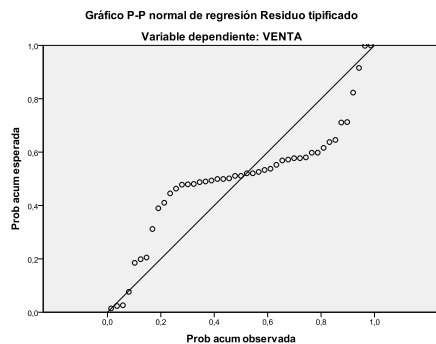
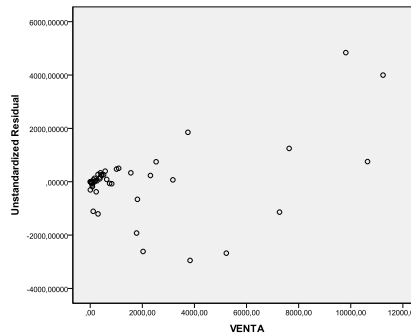
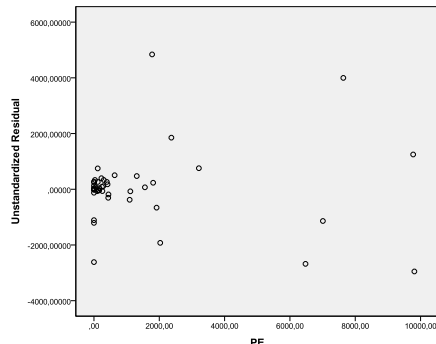
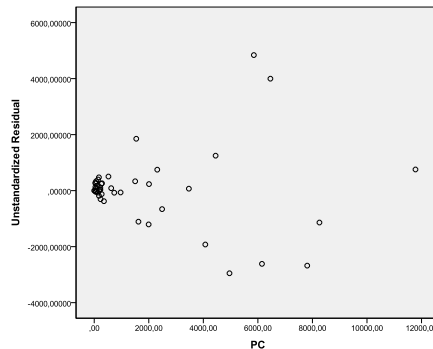
ANEXO 3. VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – GRUPO B

NORMALIDAD	Análisis 1: Histograma de los residuos	Análisis 2: Normal probability plot	Análisis 3: Test de Bondad de Ajuste. Prueba de Kolmogorov-Smirnov para una muestra (residuos no estandarizados).																								
Se corrobora con un sig. casi cercano a cero que no se cumple el supuesto de normalidad			<div>Prueba de Kolmogorov-Smirnov para una muestra</div> <table><tr><td colspan="2"></td><td>Unstandardiz ed Residual</td></tr><tr><td>N</td><td></td><td>126</td></tr><tr><td rowspan="2">Parámetros normales^{a,b}</td><td>Media</td><td>288,8856313</td></tr><tr><td>Desviación típica</td><td>3536,508472</td></tr><tr><td rowspan="3">Diferencias más extremas</td><td>Absoluta</td><td>,259</td></tr><tr><td>Positiva</td><td>,259</td></tr><tr><td>Negativa</td><td>-,183</td></tr><tr><td>Z de Kolmogorov-Smirnov</td><td></td><td>2,907</td></tr><tr><td>Sig. asintót. (bilateral)</td><td></td><td>,000</td></tr></table> <div>a. La distribución de contraste es la Normal. b. Se han calculado a partir de los datos.</div>			Unstandardiz ed Residual	N		126	Parámetros normales ^{a,b}	Media	288,8856313	Desviación típica	3536,508472	Diferencias más extremas	Absoluta	,259	Positiva	,259	Negativa	-,183	Z de Kolmogorov-Smirnov		2,907	Sig. asintót. (bilateral)		,000
		Unstandardiz ed Residual																									
N		126																									
Parámetros normales ^{a,b}	Media	288,8856313																									
	Desviación típica	3536,508472																									
Diferencias más extremas	Absoluta	,259																									
	Positiva	,259																									
	Negativa	-,183																									
Z de Kolmogorov-Smirnov		2,907																									
Sig. asintót. (bilateral)		,000																									
LINEALIDAD Y HOMOGENEIDAD DE VARIANZAS	Análisis 1. Figura de dispersión entre la variable venta y los residuos	Análisis 2. Figura de dispersión entre los residuos y el experto	Análisis 3. Figura de dispersión entre los residuos y el computador																								
Se corrobora lineabilidad y la homostecidad de los residuos, no se identifica ningún patrón en las figuras.																											

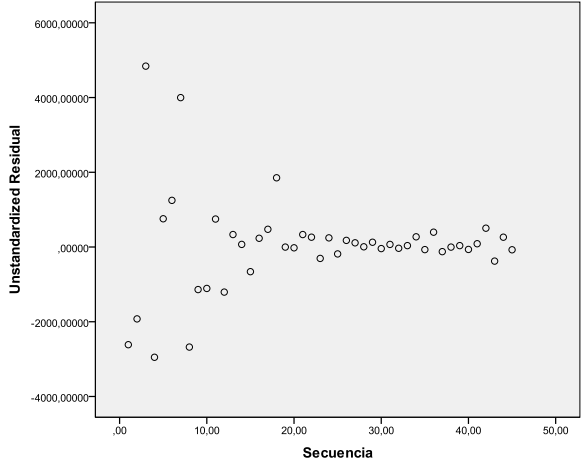
ANEXO 3. Continuación: VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – GRUPO B

INDEPENDENCIA	Análisis 1: Figura de los residuos contra secuencia de toma de datos
<p>Se corrobora independencia de los residuos, no se observa ningún patrón definido en la figura.</p>	 <p>The figure is a scatter plot titled 'Análisis 1: Figura de los residuos contra secuencia de toma de datos'. The vertical axis is labeled 'Unstandardized Residual' and ranges from -20000.00000 to 20000.00000 with major ticks every 10000.00000. The horizontal axis is labeled 'Secuencia' and ranges from 0.00 to 125.00 with major ticks every 25.00. The plot contains numerous data points represented by open circles. The points are scattered randomly around the zero line on the y-axis, with no discernible trend or pattern, which supports the assumption of independence of residuals.</p>

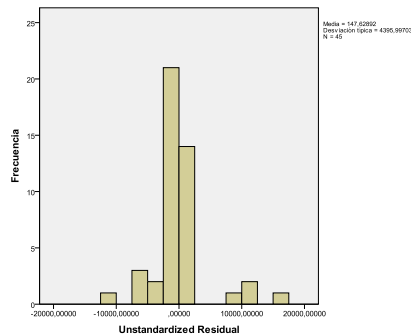
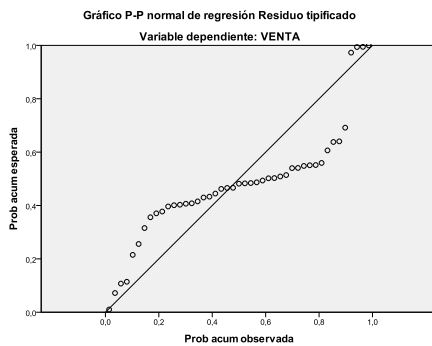
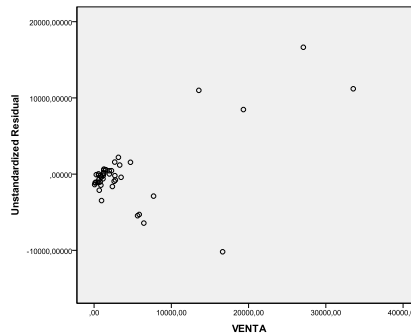
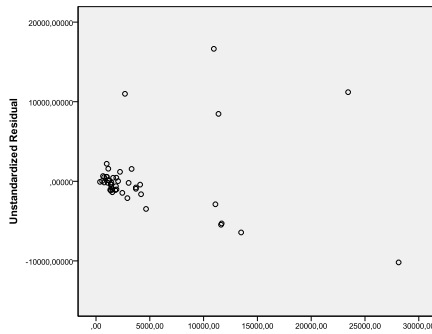
ANEXO 3. VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – INSECTICIDAS

NORMALIDAD	Análisis 1: Histograma de los residuos	Análisis 2: Normal probability plot	Análisis 3: Test de Bondad de Ajuste. Prueba de Kolmogorov-Smirnov para una muestra (residuos no estandarizados).																								
Se corrobora con un sig. de 0,016 que no se cumple el supuesto de normalidad			<div>Prueba de Kolmogorov-Smirnov para una muestra</div> <table><tr><th colspan="2"></th><th>Unstandariz ed Residual</th></tr><tr><td>N</td><td></td><td>45</td></tr><tr><td rowspan="2">Parámetros normales^{a, b}</td><td>Media</td><td>42,2770594</td></tr><tr><td>Desviación típica</td><td>1330,157144</td></tr><tr><td rowspan="3">Diferencias más extremas</td><td>Absoluta</td><td>,231</td></tr><tr><td>Positiva</td><td>,231</td></tr><tr><td>Negativa</td><td>-,210</td></tr><tr><td colspan="2">Z de Kolmogorov-Smirnov</td><td>1,550</td></tr><tr><td colspan="2">Sig. asintót. (bilateral)</td><td>,016</td></tr></table> <div>a. La distribución de contraste es la Normal. b. Se han calculado a partir de los datos.</div>			Unstandariz ed Residual	N		45	Parámetros normales ^{a, b}	Media	42,2770594	Desviación típica	1330,157144	Diferencias más extremas	Absoluta	,231	Positiva	,231	Negativa	-,210	Z de Kolmogorov-Smirnov		1,550	Sig. asintót. (bilateral)		,016
		Unstandariz ed Residual																									
N		45																									
Parámetros normales ^{a, b}	Media	42,2770594																									
	Desviación típica	1330,157144																									
Diferencias más extremas	Absoluta	,231																									
	Positiva	,231																									
	Negativa	-,210																									
Z de Kolmogorov-Smirnov		1,550																									
Sig. asintót. (bilateral)		,016																									
LINEALIDAD Y HOMOGENEIDAD DE VARIANZAS	Análisis 1. Figura de dispersión entre la variable venta y los residuos	Análisis 2. Figura de dispersión entre los residuos y el experto	Análisis 3. Figura de dispersión entre los residuos y el computador																								
Se corrobora lineabilidad y la homostecidad de los residuos, no se identifica ningún patrón en las figuras.																											

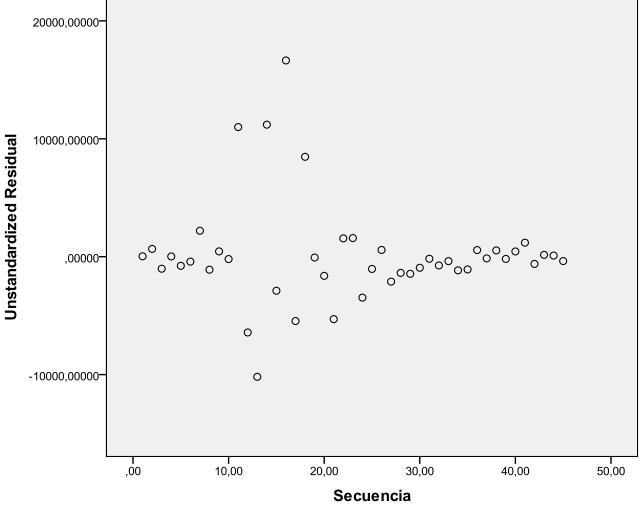
ANEXO 3. Continuación: VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – INSECTICIDAS

INDEPENDENCIA	Análisis 1: Figura de los residuos contra secuencia de toma de datos
<p>Se corrobora independencia de los residuos, no se observa ningún patrón definido en la figura.</p>	

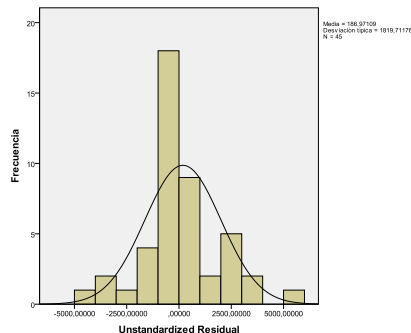
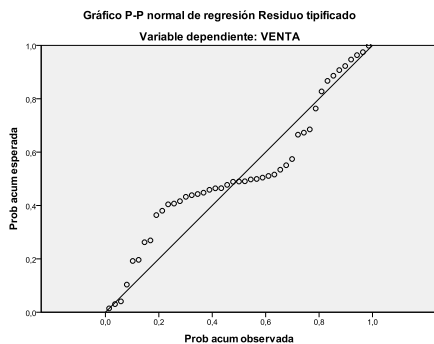
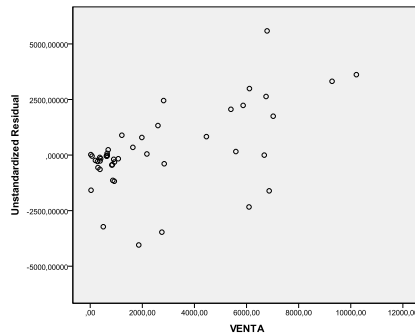
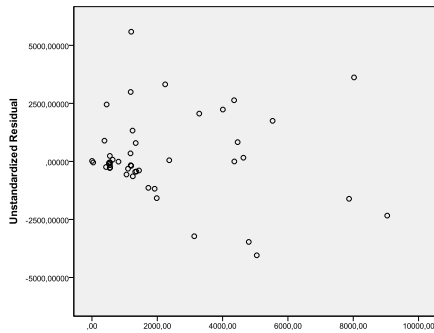
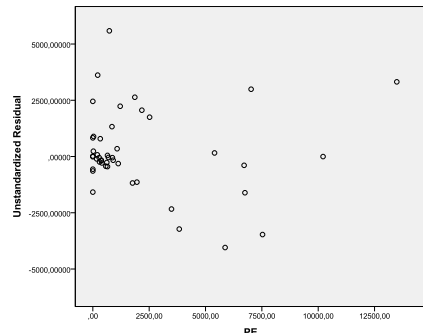
ANEXO 3. VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – HERBICIDAS

NORMALIDAD	Análisis 1: Histograma de los residuos	Análisis 2: Normal probability plot	Análisis 3: Test de Bondad de Ajuste. Prueba de Kolmogorov-Smirnov para una muestra (residuos no estandarizados).																								
Se corrobora con un sig. casi cercano a cero que no se cumple el supuesto de normalidad			<div>Prueba de Kolmogorov-Smirnov para una muestra</div> <table><tr><td colspan="2"></td><td>Unstandariz ed Residual</td></tr><tr><td>N</td><td></td><td>45</td></tr><tr><td rowspan="2">Parámetros normales^{a, b}</td><td>Media</td><td>147,6289222</td></tr><tr><td>Desviación típica</td><td>4395,997026</td></tr><tr><td rowspan="3">Diferencias más extremas</td><td>Absoluta</td><td>,276</td></tr><tr><td>Positiva</td><td>,276</td></tr><tr><td>Negativa</td><td>-,188</td></tr><tr><td>Z de Kolmogorov-Smirnov</td><td></td><td>1,851</td></tr><tr><td>Sig. asintót. (bilateral)</td><td></td><td>,002</td></tr></table> <div>a. La distribución de contraste es la Normal. b. Se han calculado a partir de los datos.</div>			Unstandariz ed Residual	N		45	Parámetros normales ^{a, b}	Media	147,6289222	Desviación típica	4395,997026	Diferencias más extremas	Absoluta	,276	Positiva	,276	Negativa	-,188	Z de Kolmogorov-Smirnov		1,851	Sig. asintót. (bilateral)		,002
		Unstandariz ed Residual																									
N		45																									
Parámetros normales ^{a, b}	Media	147,6289222																									
	Desviación típica	4395,997026																									
Diferencias más extremas	Absoluta	,276																									
	Positiva	,276																									
	Negativa	-,188																									
Z de Kolmogorov-Smirnov		1,851																									
Sig. asintót. (bilateral)		,002																									
LINEALIDAD Y HOMOGENEIDAD DE VARIANZAS	Análisis 1. Figura de dispersión entre la variable venta y los residuos	Análisis 2. Figura de dispersión entre los residuos y el computador																									
Se corrobora lineabilidad y la homostecidad de los residuos, no se identifica ningún patrón en las figuras.																											

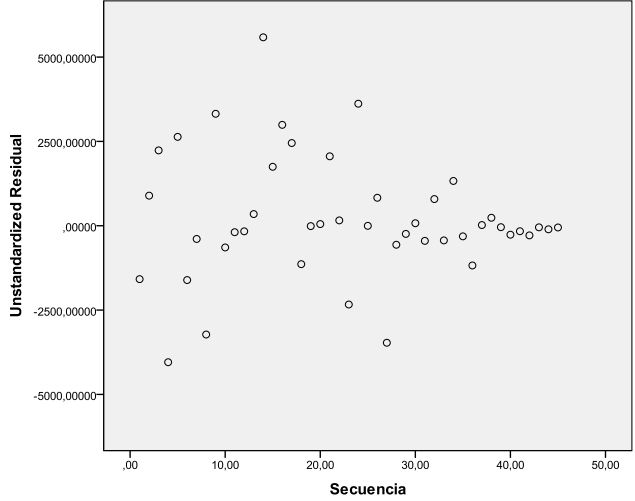
ANEXO 3. Continuación: VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – HERBICIDAS

INDEPENDENCIA	Análisis 1: Figura de los residuos contra secuencia de toma de datos
<p>Se corrobora independencia de los residuos, no se observa ningún patrón definido en la figura.</p>	

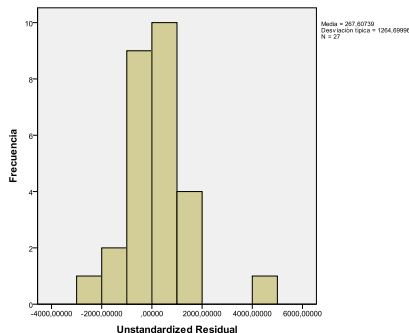
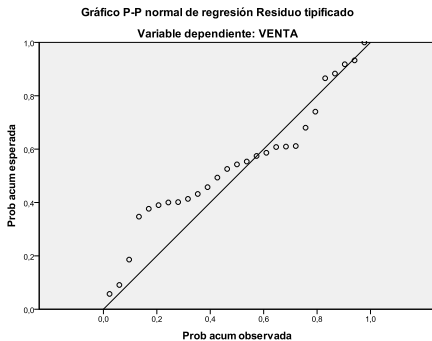
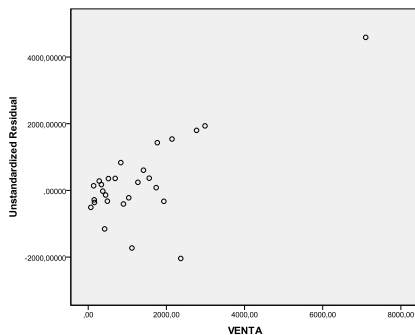
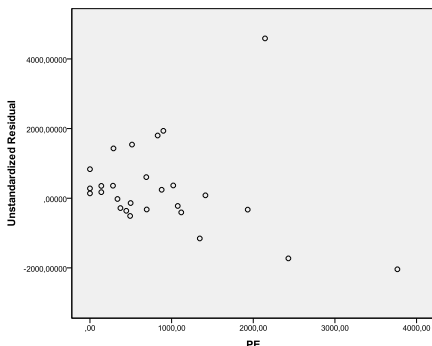
ANEXO 3. VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – FUNGICIDAS

NORMALIDAD	Análisis 1: Histograma de los residuos	Análisis 2: Normal probability plot	Análisis 3: Test de Bondad de Ajuste. Prueba de Kolmogorov-Smirnov para una muestra (residuos no estandarizados).																								
Se corrobora con un sig. de 0,115 que se cumple el supuesto de normalidad			<div>Prueba de Kolmogorov-Smirnov para una muestra</div> <table><tr><td colspan="2"></td><td>Unstandariz ed Residual</td></tr><tr><td>N</td><td></td><td>45</td></tr><tr><td rowspan="2">Parámetros normales^{a, b}</td><td>Media</td><td>186,9710918</td></tr><tr><td>Desviación típica</td><td>1819,711764</td></tr><tr><td rowspan="3">Diferencias más extremas</td><td>Absoluta</td><td>,178</td></tr><tr><td>Positiva</td><td>,178</td></tr><tr><td>Negativa</td><td>-,146</td></tr><tr><td>Z de Kolmogorov-Smirnov</td><td></td><td>1,194</td></tr><tr><td>Sig. asintót. (bilateral)</td><td></td><td>,115</td></tr></table> <div>a. La distribución de contraste es la Normal. b. Se han calculado a partir de los datos.</div>			Unstandariz ed Residual	N		45	Parámetros normales ^{a, b}	Media	186,9710918	Desviación típica	1819,711764	Diferencias más extremas	Absoluta	,178	Positiva	,178	Negativa	-,146	Z de Kolmogorov-Smirnov		1,194	Sig. asintót. (bilateral)		,115
		Unstandariz ed Residual																									
N		45																									
Parámetros normales ^{a, b}	Media	186,9710918																									
	Desviación típica	1819,711764																									
Diferencias más extremas	Absoluta	,178																									
	Positiva	,178																									
	Negativa	-,146																									
Z de Kolmogorov-Smirnov		1,194																									
Sig. asintót. (bilateral)		,115																									
LINEALIDAD Y HOMOGENEIDAD DE VARIANZAS	Análisis 1. Figura de dispersión entre la variable venta y los residuos	Análisis 2. Figura de dispersión entre los residuos y el computador	Análisis 3. Figura de dispersión entre los residuos y el experto																								
Se corrobora lineabilidad y la homostecidad de los residuos, no se identifica ningún patrón en las figuras.																											

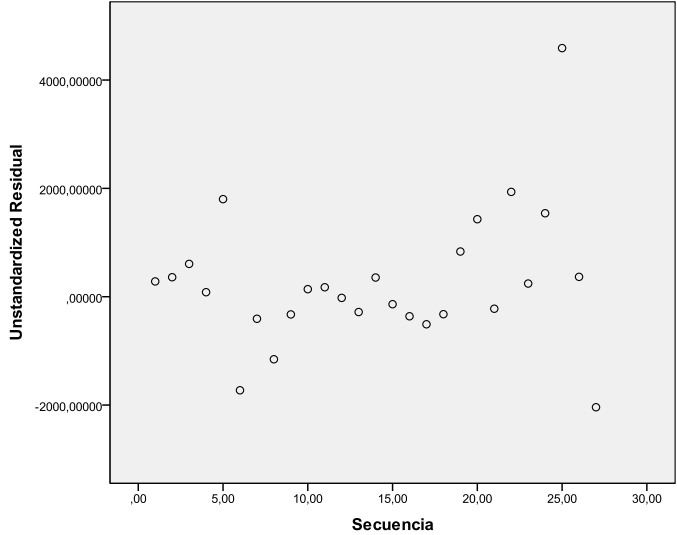
ANEXO 3. Continuación: VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – FUNGICIDAS

INDEPENDENCIA	Análisis 1: Figura de los residuos contra secuencia de toma de datos
<p>Se corrobora independencia de los residuos, no se observa ningún patrón definido en la figura.</p>	

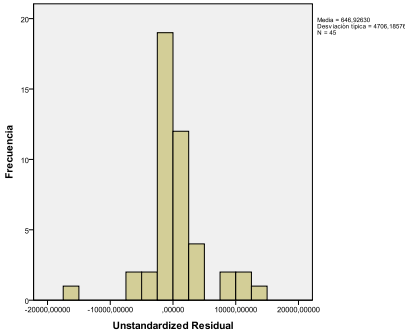
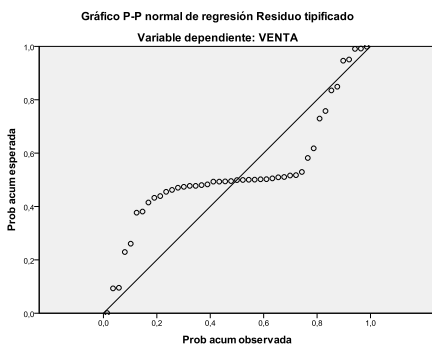
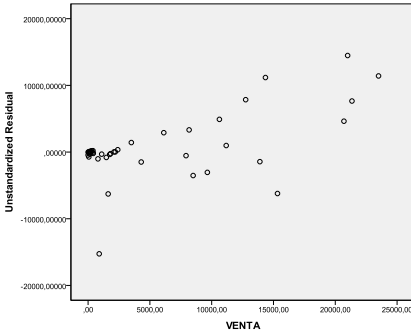
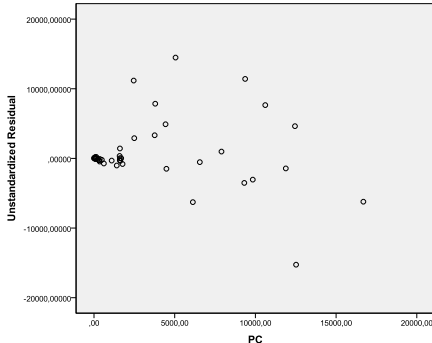
ANEXO 3. VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – COAYUDANTES

NORMALIDAD	Análisis 1: Histograma de los residuos	Análisis 2: Normal probability plot	Análisis 3: Test de Bondad de Ajuste. Prueba de Kolmogorov-Smirnov para una muestra (residuos no estandarizados).																								
Se corrobora con un sig. de 0,187 que se cumple el supuesto de normalidad			<div>Prueba de Kolmogorov-Smirnov para una muestra</div> <table><tr><th colspan="2"></th><th>Unstandariz ed Residual</th></tr><tr><td>N</td><td></td><td>27</td></tr><tr><td rowspan="2">Parámetros normales^{a, b}</td><td>Media</td><td>267,6073852</td></tr><tr><td>Desviación típica</td><td>1264,699956</td></tr><tr><td rowspan="3">Diferencias más extremas</td><td>Absoluta</td><td>,210</td></tr><tr><td>Positiva</td><td>,210</td></tr><tr><td>Negativa</td><td>-,158</td></tr><tr><td colspan="2">Z de Kolmogorov-Smirnov</td><td>1,089</td></tr><tr><td colspan="2">Sig. asintót. (bilateral)</td><td>,187</td></tr></table> <div>a. La distribución de contraste es la Normal. b. Se han calculado a partir de los datos.</div>			Unstandariz ed Residual	N		27	Parámetros normales ^{a, b}	Media	267,6073852	Desviación típica	1264,699956	Diferencias más extremas	Absoluta	,210	Positiva	,210	Negativa	-,158	Z de Kolmogorov-Smirnov		1,089	Sig. asintót. (bilateral)		,187
		Unstandariz ed Residual																									
N		27																									
Parámetros normales ^{a, b}	Media	267,6073852																									
	Desviación típica	1264,699956																									
Diferencias más extremas	Absoluta	,210																									
	Positiva	,210																									
	Negativa	-,158																									
Z de Kolmogorov-Smirnov		1,089																									
Sig. asintót. (bilateral)		,187																									
LINEALIDAD Y HOMOGENEIDAD DE VARIANZAS	Análisis 1. Figura de dispersión entre la variable venta y los residuos	Análisis 2. Figura de dispersión entre los residuos y el experto																									
Se corrobora lineabilidad y la homostecidad de los residuos, no se identifica ningún patrón en las figuras.																											

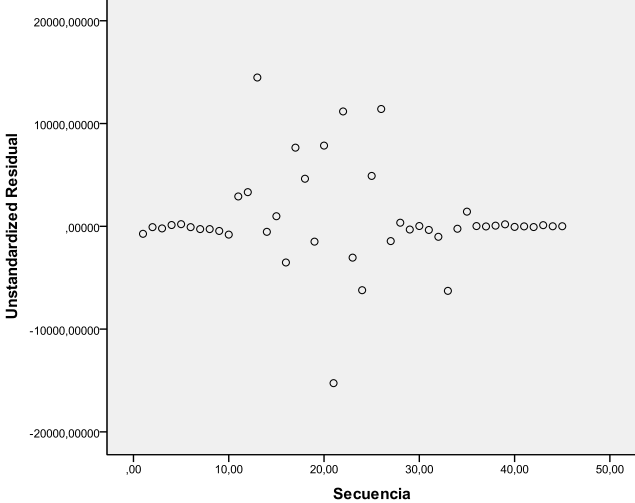
ANEXO 3. Continuación: VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – COAYUDANTES

INDEPENDENCIA	Análisis 1: Figura de los residuos contra secuencia de toma de datos
<p>Se corrobora independencia de los residuos, no se observa ningún patrón definido en la figura.</p>	

ANEXO 3. VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – FERTILIZANTES

NORMALIDAD	Análisis 1: Histograma de los residuos	Análisis 2: Normal probability plot	Análisis 3: Test de Bondad de Ajuste. Prueba de Kolmogorov-Smirnov para una muestra (residuos no estandarizados).																											
Se corrobora con un sig. casi cercano a cero que no se cumple el supuesto de normalidad			<table><tr><th colspan="3">Prueba de Kolmogorov-Smirnov para una muestra</th></tr><tr><th colspan="2"></th><th>Unstandardiz ed Residual</th></tr><tr><td>N</td><td></td><td>45</td></tr><tr><td rowspan="2">Parámetros normales^{a, b}</td><td>Media</td><td>646,9263012</td></tr><tr><td>Desviación típica</td><td>4706,185755</td></tr><tr><td rowspan="3">Diferencias más extremas</td><td>Absoluta</td><td>,281</td></tr><tr><td>Positiva</td><td>,281</td></tr><tr><td>Negativa</td><td>-,214</td></tr><tr><td>Z de Kolmogorov-Smirnov</td><td></td><td>1,883</td></tr><tr><td>Sig. asintót. (bilateral)</td><td></td><td>,002</td></tr></table> <p>a. La distribución de contraste es la Normal. b. Se han calculado a partir de los datos.</p>	Prueba de Kolmogorov-Smirnov para una muestra					Unstandardiz ed Residual	N		45	Parámetros normales ^{a, b}	Media	646,9263012	Desviación típica	4706,185755	Diferencias más extremas	Absoluta	,281	Positiva	,281	Negativa	-,214	Z de Kolmogorov-Smirnov		1,883	Sig. asintót. (bilateral)		,002
Prueba de Kolmogorov-Smirnov para una muestra																														
		Unstandardiz ed Residual																												
N		45																												
Parámetros normales ^{a, b}	Media	646,9263012																												
	Desviación típica	4706,185755																												
Diferencias más extremas	Absoluta	,281																												
	Positiva	,281																												
	Negativa	-,214																												
Z de Kolmogorov-Smirnov		1,883																												
Sig. asintót. (bilateral)		,002																												
LINEALIDAD Y HOMOGENEIDAD DE VARIANZAS	Análisis 1. Figura de dispersión entre la variable venta y los residuos	Análisis 2. Figura de dispersión entre los residuos y el computador																												
Se corrobora lineabilidad y la homostecidad de los residuos, no se identifica ningún patrón en las figuras.																														

ANEXO 3. Continuación: VALIDACION DE LOS SUPUESTOS DE REGRESION LINEAL – FERTILIZANTES

INDEPENDENCIA	Análisis 1: Figura de los residuos contra secuencia de toma de datos
<p>Se corrobora independencia de los residuos, no se observa ningún patrón definido en la figura.</p>	

ANEXO 4. ANALISIS DE CORRELACION ENTRE VARIABLES

Modelo	Correlaciones					Correlaciones					
Sin clasificación	Correlaciones				Insecticidas	Correlaciones					
			venta	experto		computador		VENTA	PC	PE	
	venta	Correlación de Pearson	1	,605**		,767**	VENTA	Correlación de Pearson	1	,872**	,735**
		Sig. (bilateral)		,000		,000		Sig. (bilateral)	,000	,000	
		N	207	207		207		N	45	45	45
	experto	Correlación de Pearson	,605**	1		,637**	PC	Correlación de Pearson	,872**	1	,678**
		Sig. (bilateral)	,000			,000		Sig. (bilateral)	,000		,000
		N	207	207		207		N	45	45	45
	computador	Correlación de Pearson	,767**	,637**		1	PE	Correlación de Pearson	,735**	,678**	1
		Sig. (bilateral)	,000	,000				Sig. (bilateral)	,000	,000	
		N	207	207		207		N	45	45	45
**. La correlación es significativa al nivel 0,01 (bilateral).					**. La correlación es significativa al nivel 0,01 (bilateral).						

Grupo A	Correlaciones			Herbicidas	Correlaciones				
		VENTA	PC			VENTA	PC		
	VENTA	Correlación de Pearson	1		,784**	VENTA	Correlación de Pearson	1	,782**
		Sig. (bilateral)			,000		Sig. (bilateral)		,000
		N	81		81		N	45	45
	PC	Correlación de Pearson	,784**		1	PC	Correlación de Pearson	,782**	1
		Sig. (bilateral)	,000				Sig. (bilateral)	,000	
		N	81		81		N	45	45
	**. La correlación es significativa al nivel 0,01 (bilateral).					**. La correlación es significativa al nivel 0,01 (bilateral).			

ANEXO 4. Continuación: ANALISIS DE CORRELACION ENTRE VARIABLES

Modelo	Correlaciones					Correlaciones					
Grupo B	Correlaciones				Fungicidas	Correlaciones					
			VENTA	PC		PE			VENTA	PE	PC
	VENTA	Correlación de Pearson	1	,767**		,619**	VENTA	Correlación de Pearson	1	,553**	,713**
		Sig. (bilateral)		,000		,000		Sig. (bilateral)		,000	,000
		N	126	126		126		N	45	45	45
	PC	Correlación de Pearson	,767**	1		,668**	PE	Correlación de Pearson	,553**	1	,414**
		Sig. (bilateral)	,000			,000		Sig. (bilateral)	,000		,005
		N	126	126		126		N	45	45	45
	PE	Correlación de Pearson	,619**	,668**		1	PC	Correlación de Pearson	,713**	,414**	1
		Sig. (bilateral)	,000	,000				Sig. (bilateral)	,000	,005	
	N	126	126	126		N	45	45	45		
** La correlación es significativa al nivel 0,01 (bilateral).					** La correlación es significativa al nivel 0,01 (bilateral).						
Coayudantes	Correlaciones				Fertilizantes	Correlaciones					
			VENTA	PE				VENTA	PC		
	VENTA	Correlación de Pearson	1	,509**		VENTA	Correlación de Pearson	1	,737**		
		Sig. (bilateral)		,007			Sig. (bilateral)		,000		
		N	27	27			N	45	45		
	PE	Correlación de Pearson	,509**	1		PC	Correlación de Pearson	,737**	1		
		Sig. (bilateral)	,007				Sig. (bilateral)	,000			
		N	27	27			N	45	45		
	** La correlación es significativa al nivel 0,01 (bilateral).					** La correlación es significativa al nivel 0,01 (bilateral).					

ANEXO 5. ANALISIS ANOVA DEL DISEÑO EXPERIMENTAL

Pruebas de los efectos inter-sujetos

Variable dependiente: MAPETOTAL

Origen		Suma de cuadrados tipo III	gl	Media cuadrática	F	Sig.
Intersección	Hipótesis	164211,307	1	164211,307	1,029	,417
	Error	319015,384	2	159507,692 ^a		
METODO	Hipótesis	8538,785	2	4269,393	,994	,446
	Error	17175,418	4	4293,855 ^b		
PRODUCTO	Hipótesis	319015,384	2	159507,692	37,148	,003
	Error	17175,418	4	4293,855 ^b		
METODO * PRODUCTO	Hipótesis	17175,418	4	4293,855	,090	,985
	Error	2141467,429	45	47588,165 ^c		

a. MS(PRODUCTO)

b. MS(METODO * PRODUCTO)

c. MS(Error)

ANEXO 5. Continuación: ANALISIS ANOVA DEL DISEÑO EXPERIMENTAL

Pruebas de los efectos inter-sujetos

Variable dependiente: MAPEIMPROVEMENTNAIVE

Origen		Suma de cuadrados tipo III	gl	Media cuadrática	F	Sig.
Intersección	Hipótesis	32520,858	1	32520,858	1,002	,422
	Error	64940,736	2	32470,368 ^a		
METODO	Hipótesis	8538,785	2	4269,393	,994	,446
	Error	17175,418	4	4293,855 ^b		
PRODUCTO	Hipótesis	64940,736	2	32470,368	7,562	,044
	Error	17175,418	4	4293,855 ^b		
METODO * PRODUCTO	Hipótesis	17175,418	4	4293,855	,263	,900
	Error	733490,687	45	16299,793 ^c		

a. MS(PRODUCTO)

b. MS(METODO * PRODUCTO)

c. MS(Error)

ANEXO 5. Continuación: ANALISIS ANOVA DEL DISEÑO EXPERIMENTAL

Pruebas de los efectos inter-sujetos

Variable dependiente: MAPEIMPROVEMENTSYSTEM

Origen		Suma de cuadrados tipo III	gl	Media cuadrática	F	Sig.
Intersección	Hipótesis	2051,747	1	2051,747	,986	,425
	Error	4163,240	2	2081,620 ^a		
METODO	Hipótesis	8538,785	2	4269,393	,994	,446
	Error	17175,418	4	4293,855 ^b		
PRODUCTO	Hipótesis	4163,240	2	2081,620	,485	,648
	Error	17175,418	4	4293,855 ^b		
METODO * PRODUCTO	Hipótesis	17175,418	4	4293,855	,965	,436
	Error	200145,950	45	4447,688 ^c		

a. MS(PRODUCTO)

b. MS(METODO * PRODUCTO)

c. MS(Error)